

SVEUČILIŠTE U ZAGREBU
FAKULTET ELEKTROTEHNIKE I RAČUNARSTVA

DIPLOMSKI RAD br. 240

Klasifikacija srčanih ritmova neuronskom mrežom

Ante Machiedo

Mentor: prof.dr.sc. Davor Petrinović

Zagreb, lipanj 2011.

Zahvaljujem se svom mentoru, prof.dr.sc. Davoru Petrinoviću, na poklonjenoj pažnji i strpljenju.

Sadržaj

1. Uvod	1
1.1. Kratak opis koncepta.....	2
2. Srce, EKG, klase signala, informacije o uzorcima i bazi.....	4
2.1. Općenito o srcu	4
2.2. EKG.....	6
2.2.1. Struktura elektrokardiograma.....	8
2.2.2. Opis srčanog ciklusa i EKG notacija	9
2.3. Klase signala.....	12
2.3.1. Normalan srčani ritam.....	12
2.3.2. Blokada desne provodne grane.....	13
2.3.3. Blokada lijeve provodne grane.....	14
2.4. Opis baze i specifikacije snimanja.....	16
2.4.1. Informacije o uzorcima za učenje i uzorcima za testiranje	17
3. Wavelet transformacija	18
3.1. Povijesni kontekst.....	18
3.2. STFT.....	20
3.3. Kontinuirana wavelet transformacija	22
3.4. Primjer analize kontinuiranom wavelet transformacijom	25
3.5. Wavelet sinteza.....	26
3.6. Diskretna wavelet transformacija.....	26
3.7. Daubechies wavelet.....	29
4. Neuronska mreža	32
4.1. Neuronske mreže.....	32
4.2. Model neurona	35
4.3. Aktivacijska funkcija <i>tansig</i>	36
4.4. Levenberg-Marquardt algoritam učenja.....	37
4.5. Parametri korištene mreže	39
5. Opis klasifikatora srčanih ritmova	40
5.1. Komponente sustava, opis metoda.....	41
5.1.1. loadDatabase.m	41
5.1.2. denoiseEm.m.....	42
5.1.3. extractFeatures.m	43

5.1.4.	markClasses.m.....	44
5.1.5.	trainECGClassifier.m	44
5.1.6.	trainNetwork.m	45
5.1.7.	validate.m.....	46
5.2.	Proces učenja neuronske mreže	46
6.	Grafičko sučelje	48
6.1.	Radna okolina	48
6.2.	Softverski paket WFDB	48
6.3.	Grafičko sučelje.....	49
6.3.1.	Primjer rada aplikacije	52
6.4.	Mogući problemi u radu.....	55
7.	Statistički podaci i analiza uspješnosti.....	56
8.	Zaključak	62
9.	Literatura	63

1. Uvod

„Osloni se na svoje srce, u protivnom ćeš izgubiti glavu.“¹

Friedrich Nietzsche

Iako se Nietzscheova izjava odnosi na simboliku koja se veže uz pojam srca u umjetnosti, odnosno unutarnjem kompasu bez kojeg bivamo izgubljeni, slično se može reći i za zbiljsko srce, fascinantni *apparatus* zaslužan za ispravan protok krvi ljudskog i životinjskog organizma. U prosječnom ljudskom vijeku od 66 godina, srce, prirodni sat, napravi oko 2.5 bilijuna otkucaja, dok je trajanje baterije ručnog sata ograničeno na otprilike maksimalno 6 godina. Pa opet, unatoč energetske učinkovitosti srca i mehanizmu koji podsjeća na ideju o *perpetuum mobile*, nije svako srce jednako zdravo. Kako bi se omogućio uvid u rad srca i shodno tome tretman liječenja, bilo je potrebno rješenje koje će omogućiti medicinsku dijagnostiku.

Prvi značajan korak na tom putu napravio je nizozemski liječnik i fiziolog, Willem Einthoven. U njegovo vrijeme bilo je dobro znano da otkucaj ljudskog srca rezultira pojavom električnog potencijala. Iskoristivši tu činjenicu, Einthoven je 1913. kreirao prvi praktični sustav za analizu rada srca, elektrokardiogram (skraćeno *EKG*). Iako su današnji EKG uređaji kompaktniji i manje robusni, terminologija i oznake ostale su iste. Razvoj računala omogućio je praktičniju analizu i arhiviranje EKG zapisa, te ponešto automatizma u samoj dijagnostici. Ipak, unatoč veoma brzom razvoju na području obrade signala, analizu samog sadržaja EKG zapisa provodi stručno osoblje, što iziskuje visoku razinu koncentracije i vremenske resurse. Nažalost, broj prijavljenih pacijenata je u konstantnom rastu, dok broj medicinskog osoblja ne prati taj trend (2008. godine je prosječan broj profesionalnog medicinskog osoblja u Republici Hrvatskoj na 100.000 stanovnika iznosio 11,801, dok je primjerice za Austriju iznosio 39,123) (EUROSTAT, 2011). Navedene činjenice predstavljaju pritisak na medicinski sektor.

¹ slobodan prijevod iz engleskog izvora

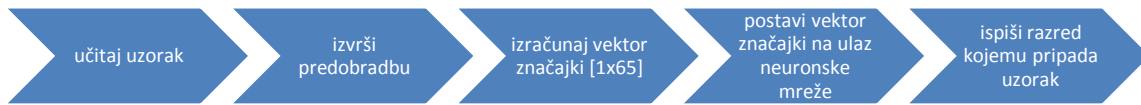
Spomenuti problemi motivacija su za odabir teme ovog rada. Ovaj će rad pokazati da tehnike poput diskretne wavelet transformacije i neuronske mreže, već ustaljene na području obrade slike i zvuka, mogu poslužiti kao izuzetno praktična podloga u medicinskoj dijagnostici pa tako i u obradi EKG zapisa, sa svrhom automatske klasifikacije srčanih ritmova. Nažalost, još uvijek ne vlada dovoljna razina svijesti o dostupnih tehnologijama iz područje obradbe informacija koji mogu naći svoju adaptaciju u medicini, pa stoga i nisu uloženi maksimalni napori da se simbioza te dvije grane znanosti unaprijedi. Perspektivno bi naprednija inačica ovakvog sustava, nimalo zahtjevna na računalne resurse, pa tako i na financijske, mogla biti i sastavni dio uređaja za analizu ritma srca u smislu prevencije oboljenja srca.

1.1. Kratak opis koncepta

Digitalizacija EKG zapisa omogućila je precizniju dijagnostiku i otvorila vrata tehnološkoj evoluciji na području obradbe informacija. Upravo zahvaljujući dostupnosti digitalnih snimaka je sustav koji je tema ovog rada ostvariv. On se oslanja na nekoliko ključnih tehnika: diskretnu wavelet transformaciju (popularno DWT^2), ekstrakciju morfoloških značajki i specijalnu kombinaciju umjetnih neurona. Za radnu okolinu odabran je programski paket MATLAB, u kojem je ujedno i implementirano grafičko sučelje (GUI^3). Uz MATLAB, korišten je WFDB *plugin* za dohvat digitaliziranog EKG-a, preporučan od strane PhysioNet kolektiva, organizacije koja prikuplja razne medicinske zapise sa svrhom unaprjeđenja medicinske dijagnostike. Sustav, treniran na bazi pacijenata grupiranih u tri različita razreda (o čemu će biti govora u poglavlju 2.3.) preuzima skup uzoraka koje želimo klasificirati, vrši predobradbu, ekstrakciju koeficijenata iz komponenata DWT -a, ekstrakciju prosječnog broja otkucaja, te nakon toga predaje vektor parametara neuronskoj mreži koja funkcionira kao klasifikator. Grubu shemu rada sustava na jednom uzorku opisuje slika 1.

² eng. *Discrete Wavelet Transform*

³ eng. *Graphical User Interface*




Slika 1: Gruba shema procesa klasifikacije (*Chevron* dijagram)

U svakom poglavlju bit će detaljno opisan postupak kreiranja ovakvog sustava, njegov trening i validacija, te će biti opisana upotrijebljena baza za učenje i validaciju, uz pripadnu statističku distribuciju i mali uvod u svaku od obrađenih klasa signala. Također, bit će opisane i sve tehnologije koje omogućuju rad, sa naglaskom na relevantnije segmente koje i sam sustav implicitno sadrži. Grafičko sučelje, radna okolina i predispozicije za rad opisani su u poglavlju 6.

2. Srce, EKG, klase signala, informacije o uzorcima i bazi

2.1. Općenito o srcu

Ljudsko srce je šuplji mišić sa četiri komore zaslužan za pumpanje krvi kroz žile općeg i plućnog krvotoka (Green & Chiaramida, 2010). Ono se nalazi u sredini grudnog koša, prostirajući se blago ulijevo i zaštićeno je prsnom kosti i rebrima. Masa mu je oko 300g i veličine je stisnute šake. Ritmički se kontrahira oko 72 puta u minuti. Srce je podijeljeno na dvije strane: lijevu i desnu. Desna strana srca sadrži desni atrij (pretklijetka) i desni ventrikul (klijetka), dok lijeva strana srca sadrži lijevi atrij i lijevi ventrikul. Lijeva i desna strana anatomski su odijeljene mišićnom pregradom, atrijskim i ventrikulskim septumom. Svaka strana srca može se razmatrati kao zasebna pumpa, pošto obje strane funkcioniraju neovisno. Tokom cirkulacije krvi desni atrij primi deoksidiranu krv iz tijela putem gornje i donje šuplje vene. Za vrijeme dijastole se krv iz desnog atrija pumpa u desni ventrikul. Potom krv iz desnog ventrikula prelazi u proces pulmonalne cirkulacije gdje se obogaćuje kisikom. Krv bogata kisikom transportirana je u lijevi atrij putem pulmonalnih vena. Slijedi period dijastole tokom koje se krv prosljeđuje u lijevi ventrikul koji potom pumpa obogaćenu krv u tijelo. Važnu ulogu u opisanom procesu cirkulacije imaju srčani zalisci ili valvule koji djeluju poput „ventila“ dopuštajući protok krvi samo u jednom smjeru. Desni atrij i desni ventrikul odijeljeni su trikuspidnom valvulom, a lijevi atrij i lijevi ventrikul mitralnom valvulom. Ove valvule poznate su još kao i kuspidne valvule. Aortalna valvula leži između lijevog ventrikula i aorte, a pulmonalna valvula dijeli desni ventrikul od pulmonalne arterije. Aortalna i pulmonalna valvula spadaju pod semilunarne valvule zbog toga što podsjećaju na polumjesec (*lat. luna* - mjesec). Navedeni segmente srca označeni su na slici 2 koja prikazuje srce u presjeku.




Slika 2: Građa srca⁴

Srce ima tri osnovna sloja: epikard, odnosno vanjski sloj mišića, miokard kao srednji sloj, te endokard ili unutarnji sloj. Miokard je tanak mišićni sloj odgovoran za proces kontrakcije. Endokard vezuje srčane valvule i komore. Krv bogatu kisikom srce prima putem dvije arterije: lijeve i desne koronarne arterije. Obje arterije izlaze iz korijena aorte, te se duž srca granaju (Koronarne arterije, 2011). Desna koronarna arterija prostire se duž koronarnog žlijeba, po kojem je i dobila ime (on se nalazi između atrija i ventrikula), sve do stražnjeg dijela ventrikulskog septuma. Ona opskrbljuje krvlju desni ventrikul, atrioventrikulski čvor, dio septuma, kao i prednje i stražnje pregrade lijevog ventrikula. Lijeva koronarna arterija započinje u lijevom sinusu aorte i prolazeći subepikardijalno između plućne arterije i lijevog atrija čini *ramus circumflexus*⁵ koji prolazi kroz koronarni žlijeb, te *ramus interventricularis anterior*⁶ koji ide kroz istoimenu brazdu na srcu. Lijeva koronarna arterija opskrbljuje krvlju prednji dio interventrikularnog septuma, lijevi atrij i ventrikul, prednji papilarni mišić u lijevom ventrikulu, mali dio desnog ventrikula, prednji papilarni mišić u desnom ventrikulu i pulmonalni konus (Jandrić). Koronarne arterije prikazuje slika 3.

⁴ http://upload.wikimedia.org/wikipedia/commons/8/82/Heart_labelled_large_prevedeno.PNG

⁵ cirkumfleksni ogranak

⁶ prednji intraventrikulski ogranak



Slika 3: Koronarne arterije

Krvotok se u čovjeka dijeli na sistemski i plućni krvotok. Sistemski krvotok je put koji krv prevari od lijevog atrija do desnog ventrikula. On dovodi u organe krv opskrbljenu kisikom, te omogućava izmjenu hranjivih tvari, plinova i otpadnih produkata. Plućni krvotok čini protok venske krvi iz čitavog tijela osim pluća prema atriju putem gornje i donje šuplje vene. Pročišćena krv opskrbljena kisikom potom iz pluća dolazi u lijevi atrij putem četiri plućne vene.

2.2. EKG

Kada je 1913. Willem Einthoven izumio elektrokardiogram, ta se naprava putem žica ili elektroda spajala na desnu ruku, lijevu ruku i lijevu nogu. Taj spoj je činio teoretski trokut. Nakon što su elektrode bile spojene na galvanometar, bilo je moguće mjeriti električnu aktivnost koju je proizvodilo srce. Ta aktivnost, koja se ocrtavala na papiru, predstavljala je individualne otkucaje srca. Moderni EKG uređaji uključuju dvanaest odvoda, odnosno različitih spajanja elektroda bilo na udovima, prsima ili kombinacijom.

Prvih šest odvoda modernog EKG-a čine Einthovenovi i pojačani (Goldbergerovi) odvodi. Spajaju se na udove i označavaju se (redom): I, II, III, aVR, aVL i aVF. Prvi Einthovenov odvod mjeren je između lijeve i desne ruke, drugi između lijeve noge i desne ruke, a treći između lijeve noge i lijeve ruke. Svaki od tih napona koji se mjere odgovaraju stranicama trokuta. Pojačani odvodi povećavaju amplitudu pojedinog uda za 50% uspoređujući potencijal jednog vrha trokuta sa srednjom vrijednosti potencijala drugih dvaju vrhova. Primjerice, povećan odvod elektrode na desnoj ruci jest razlika potencijala na toj ruci i srednjeg potencijala između suprotne lijeve ruke i noge:

$$aVR = e_1 - \frac{e_2 + e_3}{2}$$

Pošto je zbroj potencijala svih elektroda u Einthovenovoj metodi jednak nuli, odnosno:

$$e_1 + e_2 + e_3 = 0$$

Proizlazi:

$$aVR = e_1 + \frac{e_1}{2} = 1.5 e_1$$

Analogno se izvode i ostali pojačani odvodi. Einthovenovi odvodi su bipolarni, a Goldbergerovi unipolarni. Sljedećih šest odvoda nazivaju se prekordijalni odvodi i označavaju se sa: V1, V2, V3, V4, V5 i V6. To su unipolarni odvodi, a napon se mjeri na šest mjesta ispod lijeve dojke i zajedničke elektrode na nultom potencijalu koji se dobiva spajanjem sve tri elektrode preko otpora od 5 k Ω u jedno čvorište (Šantić, 1995).


EKG se najčešće ispisuje na standardizirani papir koji izlazi iz uređaja kontroliranom brzinom. Standardizirani papir se sastoji od malih kvadratića koji su široki jedan milimetar, te deblje naznačenih kvadrata koji su sastavljeni od dvadeset i pet malih. Maleni kvadratići odgovaraju vremenskom intervalu od 0.04 sekunde, a veliki 0.20 sekunde. Takva specifikacija omogućuje mjerenje vremenskog trajanja bilo kakvog valnog oblika ispisanog na papir, promatrajući valni oblik s lijeva nadesno.

2.2.1. Struktura elektrokardiograma

Normalan EKG signal sastoji se od sljedećih valova:


- P-val
- QRS kompleks
- T-val

Primjer jednog ispisa normalnog EKG signala prikazuje slika 4.



Slika 4: Normalni EKG sa naznačenim valovima

Trajanje QRS kompleksa sa slike može se zaokružiti na prostor od dva mala kvadratića, što odgovara 0.08 sekundi. Taj vremenski interval spada u granice normalnog statusa, pošto je gornja granica ove kategorije 0.1 sekunda. Sva mjerenja na amplitudnoj skali vrše se relativno u odnosu na baznu liniju. Bazna linija je imaginarna linija koja spaja kraj T-vala sa početkom P-vala. Val koji se nalazi iznad bazne linije se smatra pozitivnim, a onaj koji se provlači ispod bazne linije negativnim. U oba smjera je moguće mjeriti amplitudu vala u milimetrima. Kako bi se osiguralo ispravno mjerilo i zapis amplitude valova iznad i ispod bazne linije, uvodi se standardizirana voltaža, obično s desne strane EKG-a. Ona bi trebala iznositi točno 10 kvadratića u vertikali (slika 5).



Slika 5: Standardizirani napon

2.2.2. Opis srčanog ciklusa i EKG notacija

Ljudsko srce ima zamršen električni sustav kojeg čine specijalizirane stanice odgovorne za srčani ciklus. Specijalizirane stanice su odgovorne za pet ključnih električnih i mehaničkih funkcija:

- 1) podloga automatskom i regularnom srčanom ritmu
- 2) mogućnost međustanične komunikacije (među milijardama stanicama) u jednoj ili dvije desetine sekunde
- 3) aktivacija miokardijskih stanica
- 4) mehanizam kontrakcije
- 5) obnova sustava sa svrhom ponavljanja ciklusa, odnosno repolarizacija


Izuzev mehaničke kontrakcije, sve navedene funkcije vidljive su na EKG-u. Električni sustav srca posjeduje pet ključnih struktura: sinusno-atrijski čvor (ili SA čvor), atrioventrikulski čvor (ili AV čvor), Hisov snop, lijevu i desnu provodnu granu, te Purkinjeova vlakna. Lijevi i desni atrij kontrahiraju se u atrijskoj sistoli, kada električni impuls započne proces atrijske kontrakcije, dok se lijevi i desni ventrikul kontrahiraju u ventrikulskoj sistoli za vrijeme mehaničke kontrakcije. Sinusno-atrijski ili SA čvor je prirodni generator takta (*eng. pacemaker*) srca, pošto inicira svaki otkucaj i provodi pauzu kada je to potrebno. SA čvor čine na stotine specijaliziranih stanica, a smješten je u gornjem dijelu desnog atrija. On obično u prosjeku generira od 60 do 100 impulsa po minuti. Ti impulsi putuju duž atrija sve do atrioventrikulskog čvora i izazivaju kontrakciju atrija.

Ta električna aktivacija atrijska naziva se depolarizacija i na EKG-u je reprezentirana u obliku P-vala. P-val je najčešće prvi val, odnosno otklon na EKG-u.

Veličina, oblik i amplituda P-vala u EKG-u može varirati. Ponekad taj val može biti malen i težak za identifikaciju. P-val može biti iznad, ispod ili oscilirati oko bazne linije. Unatoč činjenici da P-val može biti malen i teško uočljiv, njegova odsutnost indikacija je abnormalnog ponašanja i sugestija da se radi o aktivaciji tzv. ektopičkih centara⁷ u području atrijske ili atrioventrikulske spojnice.

Pošto atrioventrikularni čvor, koji se nalazi u donjem dijelu desnog atrijske, primi impuls od SA čvora, on ga prosljeđuje prema Hisovom snopu. Hisov snop, smješten ispod AV čvora, širi impulse duž lijeve i desne provodne grane srca. Lijeva provodna grana vodi prema lijevom, a desna prema desnom ventrikulu. Električni stimulans putuje duž grana sve do Purkinjeovih vlakana. Konačno, miokardijske stanice se kontrahiraju, što spada u ponašanje znano kao ventrikulska sistola. Kada impuls dosegne Purkinjeovu mrežu, on se širi dalje i aktivira ili depolarizira miokardijske stanice. Navedeno stanje je ventrikulska depolarizacija, te se na EKG-u manifestira kao QRS kompleks. QRS kompleks drugi je otklon na normalnom EKG-u i sastoji se od Q-vala, R-vala i/ili S-vala, koji se pojavljuju pojedinačno ili u bilo kakvoj kombinaciji. Iako se ovakav kompleks naziva QRS kompleks, on ne mora nužno sadržavati sve navedene komponente. Ukoliko je prvi val kompleksa negativno orijentiran, radi se o Q valu. Sljedeći, pozitivno orijentiran val takvog kompleksa je R-val. Ako je pak prvi val QRS-a pozitivno orijentiran, onda je on R-val, a sljedeći S-val. Dakle, kompleks bez Q-vala se svejedno naziva QRS kompleks, dok kompleks kojem nedostaje R-val ima naziv QS kompleks. Slika 6 prikazuje jedan QRS kompleks na odvodu V6, sa svim trima valovima.

⁷ Pojava akcijskih potencijala na različitim mjestima u srcu u potpuno nepravilnim intervalima, nastala zbog povećane osjetljivosti mišićnog tkiva srca.



Slika 6: QRS kompleks

Zadnji otklon na EKG-u je T-val. T-val se pojavljuje u procesu ventrikulske repolarizacije. Ventrikuli se moraju repolarizirati kako bi započeo sljedeći ciklus kontrakcije. Jedan primjer T-vala zdravog srca prikazuje slika 7 (Green & Chiaramida, 2010).



Slika 7: Označeni T-val na odvodu V3

2.3. Klase signala

Oblik različitih segmenata EKG-a može dati korisnu informaciju o različitim oboljenjima ili biti indikator zdravog srca. Pošto postoje mnoge klase EKG zapisa ovisno o dijagnozi, u ovom radu će biti fokus na njih tri: blokada lijeve provodne grane, blokada desne provodne grane i normalan srčani ritam. Sustav koji je tema ovog rada ima sposobnost klasifikacije uzoraka u te klase.

Sustav izračunava i prosječan broj otkucaja po uzorku (tzv. *heart rate* ili *HR* faktor), čime je moguće utvrditi radi li se o normalnom ritmu, abnormalno sniženom broju otkucaja ili bradikardiji (manje od 60 otkucaja po minuti u stanju mirovanja), te abnormalno povećanom broju otkucaja ili tahikardiji (više od 100 otkucaja po minuti u stanju mirovanja). Ta informacija može imati i dijagnostički značaj za identifikaciju blokade lijeve ili desne provodne grane, kako će biti opisano daljnjim odlomcima.

2.3.1. Normalan srčani ritam

Kao što je spomenuto, srce posjeduje specijalizirane stanice koje omogućavaju pet ključnih električnih i mehaničkih aktivnosti. SA čvor čini primarnu funkciju, kreira automatski i regularni srčani ritam. Potom važnu ulogu ima AV čvor, prosljeđujući impulse između atrija i ventrikula s malom odgodom. Lijevi i desni provodni snop predstavljaju treću funkcionalnost: komunikaciju impulsima među milijardama stanica lijevog i desnog ventrikula kako bi se ostvarila gotovo istovremena kontrakcija istih. Oni prosljeđuju impulse i depolariziraju svaku od milijardu ventrikulskih stanica. Depolarizacija lijevog i desnog ventrikula u zdravog srca formira QRS kompleks u trajanju od 0.08 sekundi u prosjeku. Dakle, „poruka“ o depolarizaciji u zdravom srcu se prostire duž oba ventrikula gotovo instantno. Lijevi ventrikul ima nešto veću masu od desnog, što rezultira većim otklonom na EKG-u unatoč činjenici da se oba ventrikula depolariziraju istovremeno. Jedan primjer normalnog EKG-a u zdrave osobe već je prikazan na slici 4 (odvod II). QRS kompleks će na odvodu V2 biti negativan.

Detaljnije specifikacije normalnog srčanog ritma promatranog na EKG-u su:


- trajanje P-vala (depolarizacija atriya) manje od 0.1 sekunde
- PR interval, odnosno kašnjenje kroz AV čvor od 0.12 do 0.20 sekundi
- QRS kompleks – depolarizacija ventrikula u trajanju od manje od 0.1 sekunde (prekriva repolarizaciju atriya)
- trajanje T-vala (repolarizacija ventrikula) od oko 0.3 sekunde
- PQ interval manji od 0.2 sekunde
- pozitivan T-val
- QT interval od oko 0.42 sekunde

2.3.2. Blokada desne provodne grane

Kod blokade desne provodne grane ventrikuli se ne depolariziraju istovremeno, već slijedno, prvo lijevi ventrikul, onda desni. Slijed započinje u lijevoj provodnoj grani, koja funkcionira normalno, te se čitav lijevi ventrikul depolarizira u granicama normale, odnosno za manje od 0.1 sekunde. Dio QRS kompleksa poslije početnih 0.08 sekundi predstavlja aktivaciju samo desnog ventrikula. Taj segment odnosi se na depolarizaciju desnog ventrikula uz pomoć lijevog provodnog snopa. Pošto ovaj put depolarizacija nije sinkrona na obje strane, proces depolarizacije traje dulje (najmanje 50% dulje no za trajanja normalnog QRS kompleksa). Stoga će bilo kakvo evidentirano trajanje QRS kompleksa koje je veće od 0.12 sekundi biti znak moguće blokade provodne grane.

Široki QRS kompleks predstavljat će unikatni dijagnostički oblik na onim odvodima koji leže iznad desnog ventrikula, odnosno odvodima V1 i V2, na kojim se normalni QRS kompleks sastoji od malog pozitivnog R-vala i dubokog negativnog S-vala (odraz električne dominacije lijevog ventrikula). Kada nastupi blokada desne provodne grane, još uvijek je moguće locirati inicijalne R i S-valove pri depolarizaciji lijevog ventrikula, no zakašnjela depolarizacija desnog ventrikula bez oprečnosti lijevog ventrikula rezultira okretanjem električne osi trenutnog toka oštro udesno. Na odvodima V1 i V2 to implicira pojavu drugog R-vala, nazvanog R'. Čitav kompleks ima naziv RSR' i podsjeća na zečje uši.

Istovremeno se na lijevim lateralnim odvodima koji su smješteni iznad lijevog ventrikula (I, aVL, V5 i V6) pojavljuje recipročni kasni S-val. Primjer ovakvog ponašanje prikazuje slika 8 (Wikipedia, Right bundle branch block, 2011).




Slika 8: Odvodi V1 i V6 za vrijeme blokade desne provodne grane

2.3.3. Blokada lijeve provodne grane

Kod blokade lijeve provodne grane dolazi do zakašnjele depolarizacije lijevog ventrikula. Kao i kod blokade desne provodne grane, valja primijetiti da se to manifestira u produljenju QRS kompleksa do iznad 0.12 sekundi, te karakterističnom njegovom obliku na odvodima iznad lijevog ventrikula (I, aVL, V5 i V6). Na tim odvodima su za vrijeme ovog poremećaja vidljivi visoki R-valovi u QRS kompleksima. Odgoda depolarizacije lijevog ventrikula rezultira značajnim produženjem u dizanju tih visokih R-valova, koji će biti ili široki na vrhu ili čvorasti (slika 9). (Wikipedia, Left bundle branch block, 2011)

„Zečje“ uši su manje učestale nego u blokadi desne provodne grane. Odvodi koji snimaju iznad desnog ventrikula pokazivat će recipročne, široke i duboke S-valove. Pri blokadi lijeve provodne grane dolazi do dominacije lijevog ventrikula u toj mjeri da su moguće devijacije osi ulijevo.



Slika 9: Odvodi V1 i V6 za vrijeme blokade lijeve provodne grane

Blokada lijeve provodne grane rijetko se javlja u zdravim srcima i gotovo uvijek odražava značajnu srčanu bolest, poput degenerativne bolesti provodnog sustava ili ishemijske koronarne srčane bolesti.

U slučaju pojave blokade lijeve ili desne provodne grane, zahvaćena je i repolarizacija. Pri blokadi desne provodne grane, desni prekordijalni odvodi pokazivat će depresiju ST segmenta i inverziju T-vala, te repolarizacijske abnormalnosti. Također, pri blokadi lijeve provodne grane vidljivo je isto ponašanje na lijevim lateralnim odvodima. Oba navedena poremećaja mogu se pojavljivati povremeno ili fiksno. U nekih pacijenata se blokada provodnog snopa pojavljuje samo kada broj otkucaja srca pređe kritičnu frekvenciju. Takvo ponašanje posljedica je činjenice da je razvoj provodnog bloka striktno vezan sa vremenom potrebnim da se provodni snop repolarizira i pripremi za dolazak sljedećeg električnog impulsa. Ukoliko je frekvencija srca tako brza da se snop ne može repolarizirati na vrijeme, nastat će privremena blokada provođenja, što ima kao posljedicu karakteristični EKG oblik sa frekvencijom povezane blokade provodnog snopa.

2.4. Opis baze i specifikacije snimanja

Baza koja se koristi u ovom radu produkt je suradnje između bolnice Beth Israel (BIH) u Bostonu i MIT-a (Massachusetts Institute of Technology), započete 1975. godine. Radi se o MIT-BIH bazi pacijenata koji imaju bilo kakav znak aritmije. Izvorno, baza se sastoji od digitaliziranih zapisa EKG-a 47 pacijenata: 25 muškaraca u dobi od 32 do 89 godina, te 22 žene u dobi od 23 do 89. Pacijenti su snimani 24 sata snimani Holter monitorom, kompaktnijim uređajem za snimanje EKG-a. Iz opsežnije baze Holter-snimaka postupkom slučajnog odabira odabrani su određeni uzorci i digitalizirani frekvencijom otipkavanja od oko 360 uzoraka u sekundi po svakom od dva odvoda EKG-a koji su se koristili: II i V1, uz ukupno vrijeme pohrane od 30 minuta (Moody, 2010). Rezolucija snimanja je 11-bitna, a naponski raspon ± 5 mV. Dvoje ili više kardiologa ručno je označilo svaki digitalizirani zapis, čime je omogućena *a priori* dijagnostička informacija o pacijentima, priložena uz svaku datoteku. Zapisi koji su korišteni u ovom radu preuzeti su sa portala PhysioBank, koji čuva popis svih javno dostupnih digitaliziranih zapisa medicinske instrumentacije. Zapisi su u razvojnu okolinu MATLAB transferirani pomoću *plugina* WFDB⁸, a datoteke iz kojih se oni transferiraju imaju .DAT ekstenziju. Spomenute oznake stručnih kardiologa priložene su u obliku datoteke sa zaglavljem (*header file*, ekstenzija .HEA). Za potrebe ovog rada, iz dostupne baze eliminirani su svi pacijenti čija dijagnoza ne spada u jednu od tri kategorije: normalan srčani ritam, blokada lijevog provodnog bloka i blokada desnog provodnog bloka.

⁸ eng. *Waveform Database*, plugin za MATLAB kojim je omogućeno učitavanje EKG zapisa u matrice strukture

2.4.1. Informacije o uzorcima za učenje i uzorcima za testiranje

Pošto su na PhysioBank portalu locirani MIT-BIH zapisi pacijenata čija dijagnoza odgovara klasama koje raspoznaje ovaj sustav, svaka od datoteka koja čini prostor za učenje podijeljena je na dvadeset segmenata varijabilne duljine (ovisno o frekvenciji srca). Točnije, unutar svake klase izdvojen je određen broj pacijenata, te je zapis segmentiran na dvadeset segmenata, tako da se svaki segment sastoji od sedam otkucaja srca. Otkucaji su detektirani specijalnom MATLAB naredbom, što je opisano u poglavlju 5.1.1. Također, uzorci za testiranje ili validaciju sustava sličnim su postupkom ekstrahirani, uz činjenicu da se taj skup razlikuje od uzoraka za učenje (različiti pacijenti i različiti vremenski okviri segmentacije). Sumarno, prostor uzoraka za učenje čini 180 uzoraka (60 uzoraka po klasi), dok prostor uzoraka za testiranje čini oko 380 uzoraka. Detaljniju analizu uzoraka i točnost klasifikacija istih prikazuje poglavlje 7.

3. Wavelet transformacija

3.1. Povijesni kontekst

Iako inicijalno namijenjeno rješavanju problema toplinskog vođenja i vibracija, otkriće francuskog matematičara Josepha Fouriera, danas znano kao Fourierova transformacija omogućilo je pogodniju ekstrakciju informacije iz mnogih procesa koji se dadu reprezentirati formulativno, najčešće u vremenskoj domeni. Preciznije, taj matematički aparat ukazuje na zanimljiva svojstva određenog signala preslikavajući signal iz vremenske (ili prostorne, kao što je to slučaj kod digitalne obrade slika) u frekvencijsku domenu. 1822., Fourier je pokazao da se svaka periodična funkcija može izraziti preko beskonačne sume periodičnih kompleksnih eksponencijalnih funkcija. Nešto kasnije su isti principi generalizirani i na aperiodične funkcije, te potom na periodične i aperiodične vremenski diskretne signale, što je otvorilo vrata njihovoj primjeni u računalima (1965. godine razvijen je *Fast Fourier Transform* ili FFT, koji je dodatno popularizirao upotrebu Fourierove transformacije).

Matematička formulacija Fourierove transformacije i njezinog inverza glasi:

$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} dt \quad (1)$$

$$x(t) = \int_{-\infty}^{\infty} X(f) \cdot e^{j2\pi ft} df \quad (2)$$

Pritom t predstavlja vrijeme, f frekvenciju, dok $x(t)$ označava signal kao funkciju vremena. $X(f)$ jest signal u frekvencijskoj domeni, odnosno Fourierova transformacija signala $x(t)$. Eksponencijalna funkcija u jednadžbi (1) može se preko Eulerove formule izraziti kao:


$$\cos(2\pi ft) + j \sin(2\pi ft) \quad (3)$$

Vidljivo je da se gornja jednadžba sastoji od realne i imaginarne komponente.

Dakle, u pozadini Fourierove transformacije odvija se integracija produkta originalnog signala i kompleksnog izraza koji se sastoji od sinusnih i kosinusnih funkcija frekvencije f , što implicira da će rezultat ove integracije biti velika vrijednost ukoliko signal $x(t)$ ima dominantnu spektralnu komponentu na frekvenciji f . Ukoliko to nije slučaj, vrijednost integracije bit će mali broj ili nula ako signal uopće ne posjeduje komponentu pri f . Očito je da se gornji izrazi evaluiraju za svaku vrijednost f .

Fourierovom transformacijom postavio se naglasak na spektralnu analizu, često korištenu u području digitalne obrade i analize signala, te estimacije. Uzmimo za primjer medicinsku dijagnostiku. Kardiolozima je dobro poznat oblik EKG-a zdrave osobe. Bilo kakva značajnija devijacija od tog obrasca vjerojatno će im ukazati na simptome patološkog poremećaja. Međutim, poremećaj možda neće biti vidljiv u izvorišnoj vremensko-amplitudnoj reprezentaciji signala. Kardiolog stoga dobiva na preciznosti koristeći opremu koja posjeduje spektralne analizatore kao podršku pri dijagnozi.

Unatoč praktičnoj primjeni Fourierove transformacije, pokazuje se da ona nije pogodna za analizu nestacionarnih signala (onih čiji se frekvencijski sadržaj mijenja u vremenu). Obrazloženje te tvrdnje leži u činjenici da se Fourierova transformacija izvodi duž čitave vremenske osi promatranog signala, što ponekad rezultira podjednakim spektralnim slikama za određene stacionarne i nestacionarne signale. Takvo ponašanje Fourierove transformacije često krije samu narav procesa. Primjerice, signal koji se sastoji od sume kosinusnih funkcija različitih frekvencija može imati sličan spektar kao i kosinusni signal čija se frekvencija u vremenu mijenja (slika 10).



Slika 10: Demonstracija mogućeg scenarija pri spektralnoj analizi – sličnost u spektralnim slikama za stacionaran i nestacionaran proces

Ukoliko je potrebno poznavati vremensku distribuciju frekvencijskih komponenti, transformacije poput one koja je tema ovog poglavlja pružaju prikladniju alternativu. Kako će se pokazati kasnije u ovom radu, pri analizi procesa koji se u vremenu mijenjaju (kao što je EKG signal) distinkcija između određenih obrazaca ostvariva je vremenskom lokalizacijom spektralnih komponenti. Jedno od mogućih rješenja za taj problem pruža *wavelet transformacija*.

3.2. STFT

Da bi princip rada wavelet transformacije bio jasan, potrebno je shvatiti koncepte koji se kriju iza poboljšane inačice Fourierove transformacije, tzv. vremenski kratkotrajne ($STFT^9$) transformacije i uočiti njezine mane. Glavna ideja iza $STFT$ transformacije leži u pretpostavci da je signal stacionaran za dovoljno malenu regiju promatranja. Za tu svrhu se koristi funkcija prozora W čija širina mora odgovarati segmentu signala u kojem se može pretpostaviti stacionarnost.


⁹ eng. *Short-Time Fourier Transform*

Prozor se na početku izračuna postavlja na sam početak signala, odnosno pozicionira u $t=0$. Ukoliko je širina prozora označena sa L , u prvom koraku izračuna će se prozor preklapati sa $L/2$ jedinica promatranog signala. Tada se signal množi s prozorom duž $L/2$ jedinica, te se izluči Fourierova transformacija produkta koja će predstavljati dobru frekvencijsku reprezentaciju ako je signal u tom segmentu stacionaran. Nakon toga se prozor pomiče za korak τ , te se čitava procedura ponavlja dok nije pokriven interesantan opseg signala (u praksi se analiziraju signali konačnog trajanja, računala mogu matematičke apstrakcije poput beskonačnog trajanja rješavati samo simbolički). Navedeni postupak može se matematički izraziti:

$$STFT_x^{(W)}(\tau, f) = \int_t [x(t) \cdot W^*(t - \tau)] \cdot e^{-j2\pi ft} dt \quad (4)$$

(Napomena: funkcija prozora je u ovoj formulaciji kompleksni konjugat)

Može se primijetiti da se $STFT$ računa za svaki pomak prozora τ i odabranu frekvenciju f . Na taj način se dobiva vremensko-frekvencijska reprezentacija signala. Jedan primjer $STFT$ transformacije signala prikazuje slika 11.



Slika 11: Primjer 3D $STFT$ grafa sa naznačenim osima: vremenska, frekvencijska i amplitudna¹⁰

¹⁰ <http://rush3k.blog-city.com/arrghh.htm>

Iako *STFT* pruža određeni kompromis između frekvencijske i vremenske razlučivosti, zbog Heisenbergovog principa neodređenosti¹¹ i ovisnosti o duljini prozora rezultati mogu biti jako varljivi. Uski prozor analize rezultirat će boljom vremenskom rezolucijom i slabom frekvencijskom rezolucijom. S druge strane, široki prozor polučit će bolju razlučivost u frekvenciji, a lošiju u vremenu. Fourierova transformacija zbog eksponencijalne funkcije beskonačnog trajanja kao jezgre pruža dobru frekvencijsku rezoluciju, no ona zato ne daje nikakvu informaciju o vremenu u frekvencijskoj domeni, kao ni obratno. *STFT*, kako je gore spomenuto, unaprjeđenje je tog problema, no zbog fiksne veličine odabranog prozora prikaz frekvencijskih pojaseva za određene vremenske intervale varira u razlučivosti.

3.3. Kontinuirana wavelet transformacija

Jedno od mogućih rješenja za mane *STFT*-a nudi kontinuirana wavelet transformacija (*CWT*¹²). Umjesto množenja funkcijom prozora, kod kontinuirane wavelet transformacije se signal množi wavelet-funkcijom. Kod ovakve transformacije se koeficijenti također računaju za različite segmente signala u vremenskoj domeni. Bitno je naglasiti da se kod wavelet transformacije nad segmentima signala ne računa Fourierova transformacija, te da je širina waveleta, tzv. skala, promjenjiva.

Kontinuirana wavelet transformacija definira se kao:

$$CWT_x^\psi(\tau, s) = \Psi_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \cdot \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (5)$$

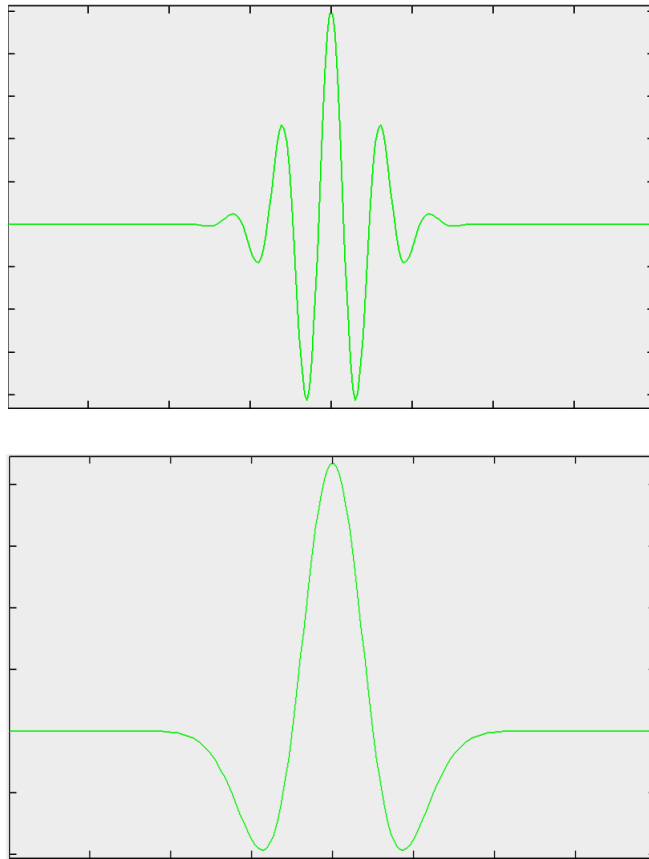
Transformirani signal funkcija je dvije varijable, τ i s , odnosno translacije i skale redom. Funkcija ψ naziva se osnovna wavelet funkcija ili *mother wavelet*, pošto ona služi kao prototip pri izvođenju svih ostalih funkcija u procesu transformacije. Parametar translacije odnosi se na lokaciju waveleta u procesu transformacije, te ima značenje analogno pomaku prozora u *STFT*-u.

¹¹ Heisenbergov princip neodređenosti problem je iz fizike koji je originalno ukazivao na nemogućnost istodobnog preciznog mjerenja položaja i brzine čestice, ali se u obradi informacije problematika proširuje na vremensko-frekvencijsku informaciju o signalu.

¹² eng. Continuous Wavelet Transform

Wavelet transformacija ne koristi frekvenciju kao parametar, već skalu, koja je obrnuto proporcionalna frekventijskom pojasu. Značenje tog parametra slično je značenju mjerila u kartografiji; veća mjerila odgovaraju globalnom, manje detaljnom pogledu, dok manja mjerila odgovaraju detaljnom pogledu. Analogno je u spektralnoj domeni; niže frekvencije (više skale) obično se odnose na globalnu informaciju u signalu, a više frekvencije (niže skale) odnose se na detaljan prikaz skrivenog uzorka u signalu, onoga čije je trajanje kraće. Kao matematička operacija, skaliranje vrši dilataciju ili kompresiju signala. Prema definiciji kontinuirane wavelet transformacije, slijedi da će se uz $s > 1$ vršiti dilatacija waveleta koji se koristi, a uz $s < 1$ kompresija.

Opišimo proceduru izračuna kontinuirane wavelet transformacije. Neka je $x(t)$ signal koji će se analizirati. Prvi korak povlači odabir osnovnog waveleta koji će služiti kao prototip za sve prozore analize. Svi izvedeni prozori potom su dilatirane ili komprimirane vremenski pomaknute inačice osnovnog waveleta. Kao osnovni wavelet, može se koristiti čitav spektar funkcija, primjerice Morletov wavelet ili meksički šešir (slika 12). Nakon što je odabran osnovni wavelet, izračun započinje postavljanjem parametra skale $s = 1$, nakon čega se kontinuirana wavelet transformacija računa za vrijednosti manje ili veće od početne. U praksi su signali frekventijski ograničeni pa se postavlja interval skala koji će se pokriti.



Slika 12: Primjer osnovnih waveleta:
Morletov wavelet (gore), meksički šešir (dolje)

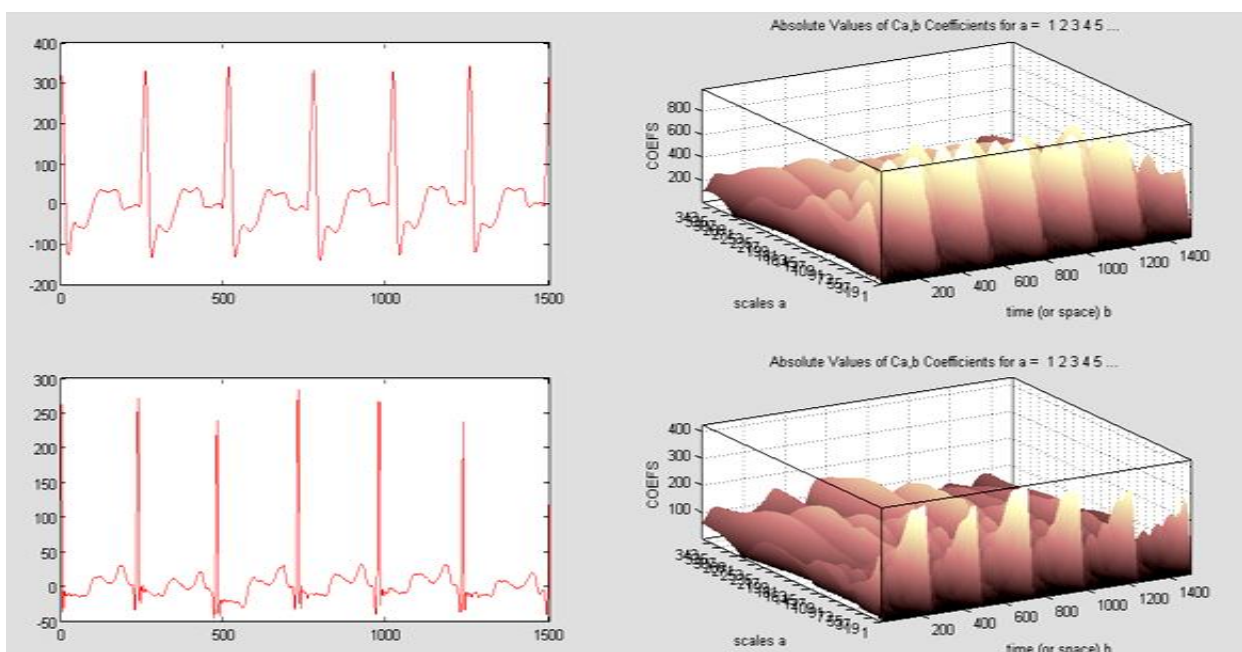
Demonstracije radi, neka transformacija započne od $s = 1$, te neka s u procesu raste. Wavelet će u početnom koraku biti najviše komprimiran, te će postepeno dilatirati. Wavelet se postavlja na početak signala, u trenutku $\tau = 0$. Tako postavljen wavelet množi se sa signalom i produkt se integrira duž čitavog okvira analize. Integral se množi s vrijednošću $\frac{1}{\sqrt{|s|}}$, čime se normalizira energija. Konačan rezultat je vrijednost kontinuirane wavelet transformacije za $s = 1$ i $\tau = 0$. Wavelet se u sljedećem koraku pomiče za neki $\tau \neq 0$ i čitava procedura se ponavlja dok nije dosegnut kraj signala. Time je generiran jedan red *CWT* koeficijenata za vrijednost skale $s = 1$. Potom se vrijednost skale s uveća za neki manji broj i novi red *CWT* koeficijenata se računa duž signala analogno prethodno opisanim koracima. Valja napomenuti da se pri računalnom izvođenju *CWT*-a s i τ inkrementiraju za dovoljno mali korak.

Analiza kontinuiranom wavelet transformacijom u suštini jest mjera korelacije između bazne funkcije (waveleta) i samog signala, u smislu frekvencijskog sadržaja.

Točnije, izračunati *CWT* koeficijenti odnose se na sličnost signala waveletu na trenutnoj skali. Ako pri analizi signal posjeduje dominantnu spektralnu komponentu koja se podudara s trenutnom skalom (podsjetimo, skala ima obratno proporcionalan odnos prema frekvenciji), tada će wavelet biti sličan ili blizak signalu na poziciji na kojoj se ta spektralna komponenta pojavljuje. Posljedica toga je veća vrijednost *CWT* koeficijenta.

3.4. Primjer analize kontinuiranom wavelet transformacijom

Slika 13 prikazuje usporedbu dvaju medicinskih signala pri analizi kontinuiranom wavelet transformacijom. U radnoj okolini programskog paketa MATLAB učitana je baza pacijenata, te su odabrana dva pacijenta iz različite skupine, za demonstraciju *CWT* analize. Prvi par grafova odnosi se na analizu EKG zapisa (gore lijevo) pacijenta koji ima blokadu lijeve provodne grane (opisano u poglavlju 2.3.3.), dok je pri dnu prikazana analiza EKG-a pacijenta čije srce ne pokazuje znakove patološkog poremećaja (zdravo srce).



Slika 13: *CWT* analiza EKG-a dvaju pacijenata

Iz priloženog je moguće uočiti prednosti wavelet analize; rezolucija u vremenu i frekvenciji je zadovoljavajuća.

3.5. Wavelet sinteza

Signal se iz koeficijenata kontinuirane wavelet transformacije može rekonstruirati. Rekonstrukcija se vrši na sljedeći način:

$$x(t) = \frac{1}{c_\psi^2} \iint_{s,\tau} \Psi_x^\psi(\tau, s) \frac{1}{s^2} \psi\left(\frac{t-\tau}{s}\right) d\tau ds \quad (6)$$

Uspješnost rekonstrukcije ovisi o konstanti c_ψ , koja se naziva *granica dopustivosti*. Ona zadovoljava sljedeći uvjet:

$$c_\psi = \left\{ 2\pi \int_{-\infty}^{\infty} \frac{|\hat{\psi}(\xi)|^2}{|\xi|} d\xi \right\}^{1/2} < \infty \quad (7)$$

gdje je $\hat{\psi}(\xi)$ Fourierova transformacija od $\psi(t)$.

Gornji uvjet implicira da je $\hat{\psi}(0) = 0$, što povlači i nužnost

$$\int \psi(t) dt = 0 \quad (8)$$

Drugim riječima, ta matematička restrikcija ograničava odabir waveleta na one čiji integral je jednak nuli.

3.6. Diskretna wavelet transformacija

Kontinuirana wavelet transformacija, kao i njena diskretizirana inačica, posjeduje podosta redundantnosti kada je rekonstrukcija signala u pitanju. Time ima i veće zahtjeve na računalne resurse. Često je praktičnije koristiti diskretnu wavelet transformaciju, koja će većom brzinom dati dobre rezultate pri analizi i sintezi. Ujedno je i nešto jednostavnija za izvedbu.

Kod diskretne wavelet transformacije se za analizu signala na različitim skalama upotrebljavaju filtri različitih graničnih frekvencija (Polikar, 2000). Visoke frekvencije analiziraju se visokopropusnim, a niske frekvencije niskopropusnim filtrima. Detaljnost informacije o signalu, odnosno rezolucija, mijenja se filtriranjem, dok se skala mijenja poduzorkovanjem i naduzorkovanjem.

Poduzorkovanje signala za neki faktor N rezultira redukcijom broja uzoraka u signalu za N puta. Primjerice, poduzorkovanje s faktorom $N = 2$ znači odbacivanje svakog drugog uzoraka u signalu. Naduzorkovanje signala dodaje uzorke signalu, najčešće nul-vrijednosti ili interpolirane vrijednosti, tako da će signal nad kojim je izvršeno naduzorkovanje s faktorom N , imati N puta više uzoraka.

Diskretna wavelet transformacija prvotno promatrani signal propušta kroz niskopropusni *half-band* filter (digitalni filter koji uklanja sve spektralne komponente iznad polovice najviše frekvencije) s impulsnim odzivom $h[n]$, što u matematičkom smislu odgovara operaciji konvolucije signala sa impulsnim odzivom filtra:

$$x[n] * h[n] = \sum_{k=-\infty}^{\infty} x[k] \cdot h[n - k] \quad (9)$$

U diskretnoj domeni je fokus na kružnu frekvenciju (mjeri se u radijanima po sekundi), koja se najčešće označava grčim slovom ω . Relacija kružne frekvencije i originalne frekvencije je:

$$\omega = 2\pi f \text{ [rad/s]}$$

Stoga je vrijednost najveće moguće spektralne komponente je jednaka π , ukoliko je originalni signal uzorkovan prema *Nyquist-Shannonovom* teoremu uzorkovanja:

$$f_s > 2B$$

B pritom označava najvišu frekvenciju pri kojoj promatrani signal može imati signifikantnu energiju. Nakon što je signal propušten kroz niskopropusni *half-band* filter, polovica uzoraka može se eliminirati, pošto tako filtriran signal tada posjeduje najvišu spektralnu komponentu pri $\frac{\pi}{2}$ rad/s. Da bi se ostvario taj cilj, signal se poduzorkuje s faktorom 2. Propuštanje signala kroz niskopropusni *half-band* filter dvostruko umanjuje razlučivost signala, no poduzorkovanje udvostručuje skalu. Izlaz $y[n]$ iz tako opisanog sustava može se opisati formulom:

$$y[n] = \sum_{k=-\infty}^{\infty} h[k] \cdot x[2n - k] \quad (10)$$

Diskretna wavelet transformacija analizira signal na različitim frekvencijskim pojasevima, uz varijabilnu rezoluciju, vršeći dekompoziciju signala u grube aproksimacijske koeficijente i detalje.

Dekompozicija signala na različite frekvencijske pojaseve vrši se opetovanim prolaskom kroz visokopropusni i niskopropusni filter. Osim opisanog postupka provlačenja signala kroz niskopropusni *half-band* filter, signal $x[n]$ se filtrira i viskopropusnim *half-band* filtrom, koji će u ovoj dokumentaciji biti označen sa $g[n]$. Nakon filtriranja se polovica uzoraka može ukloniti, kao što je opisano gornjom *Nyquist-Shannonovom* relacijom. Postupak filtriranja i poduzorkovanja (prvi nivo dekompozicije) opisuju sljedeće jednačbe:


$$y_{VP}[k] = \sum_n x[n] \cdot g[2k - n] \quad (11)$$

$$y_{NP}[k] = \sum_n x[n] \cdot h[2k - n] \quad (12)$$


Pritom $y_{VP}[k]$ označava izlaz iz viskopropusnog *half-band* filtra ili aproksimacijske koeficijente, nakon poduzorkovanja, a $y_{NP}[k]$ izlaz iz niskopropusnog segmenta, odnosno detalje.

Fokusirajući se na posljedice ovakve dekompozicije, usporedivši sa problematikom rezolucije signala u vremenu i frekvenciji, jasno je da će opisani postupak rezultirati dvostruko manjom vremenskom rezolucijom, pošto je i broj uzoraka koji karakterizira promatrani signal dvostruko manji. Ali, zato je rezolucija u frekvenciji dvostruko veća pošto je obuhvaćena polovica prethodnog frekvencijskog pojasa, a to za posljedicu ima dvostruko manju nesigurnost pri razaznavanju frekvencije.

Dekompozicija se može analogno nastaviti na više razina, tako da se u sljedećem koraku vrši dekompozicija aproksimacijskih koeficijenata, odnosno signala $y_{NP}[k]$. Ako je originalni signal bio duljine L , diskretna wavelet transformacija može se izvesti u najviše $\log_2 L$ faza. Duljina svakog od filtara obično je $2L$. Slika 14 opisuje jedan nivo dekompozicije, dok slika 15 prezentira stablastu strukturu višerazinske wavelet dekompozicije.



Slika 14: Jedna razina *DWT* dekompozicije signala



Slika 15: Hijerarhijska struktura wavelet dekompozicije u n razina

3.7. Daubechies wavelet

Kao što je ranije spomenuto, relacija (8) predstavlja nužan uvjet pri modeliranju waveleta u svrhe analize i sinteze. Ta relacija se ujedno naziva i nulti moment funkcije $\psi(t)$. Ako ona vrijedi, kažemo da $\psi(t)$ ima nulti moment iščezavanja. Slično, možemo pisati:

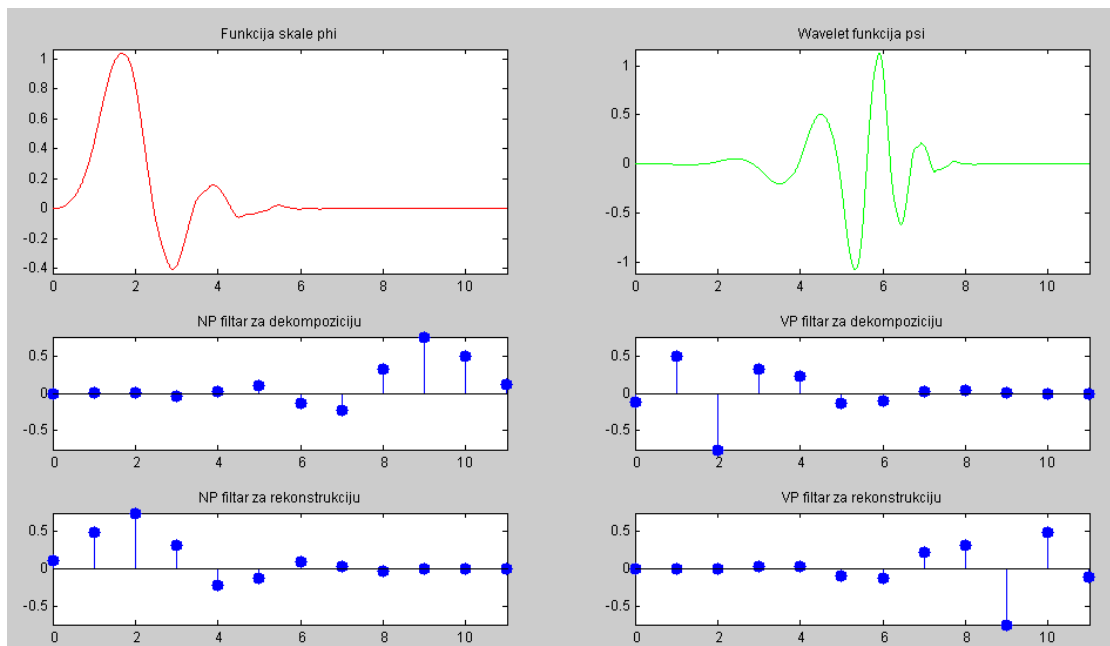
$$\int t^k \psi(t) dt = 0$$

U tom slučaju kažemo da $\psi(t)$ ima k -ti moment iščezavanja. S obzirom na moment iščezavanja, waveleti mogu imati tri važna svojstva: glatkost, aproksimacija i reprodukcija polinoma. Što je funkcija glađa, to ona ima više momenata iščezavanja. Drugo svojstvo odnosi se na broj koeficijenata potreban za aproksimaciju. Pokazuje se da ukoliko je wavelet gladak, odnosno ima mnogo momenata iščezavanja, potrebno je manje koeficijenata za aproksimaciju nekog promatranog signala. To ima svoju praktičnu primjenu i u kompresiji slike; ukoliko se slika sastoji od glatkih prijelaza, nije potrebno čuvati mnogo wavelet koeficijenata, dok u protivnom je.

Treće pravilo ima sofisticiranije implikacije, ali može se interpretirati na sljedeći način:

Pošto bilo se bilo koja glatka funkcija može aproksimirati polinomom, ona se stoga može i reprezentirati sa manjim brojem wavelet koeficijenata. (Walnut, 2002)

Za potrebe realizacije sustava koji je tema ovog rada koriste se Daubechies waveleti, koji ispunjavaju navedene uvjete. Od mogućih varijanti, sustav koji je tema ovog rada oslanja se na varijantu Daubechies 6 (skraćeno db6). Daubechies waveleti često se koriste jer imaju velik broj momenata iščezavanja. Ukoliko te momente označimo sa A (ujedno i red aproksimacije), za dani okvir širine $N = 2A$ se iz 2^{A-1} rješenja odabire ono za koje filter daje maksimalnu fazu (Wikipedia, Daubechies wavelet, 2011). Daubechies waveleti tvorevina su belgijske matematičarke Ingrid Daubechies, te se ne mogu zapisati u zatvorenoj matematičkoj formi. Često se upotrebljavaju pri analizi medicinskih signala, fraktalnih oblika, diskontinuiteta u signalima i sl. Razlog upotrebe upravo db6 waveleta u ovom radu leži u činjenici da oblik tog waveleta ima iznimne sličnosti sa EKG zapisom (Sahab & Gilmalek, 2011), što će rezultirati pogodnijem ponašanju pri analizi digitaliziranih zapisa (kao što je opisano u poglavlju 3.3.). Prikaz db6 waveleta zajedno sa korespondentnim filtrima prikazuje slika 16.



Slika 16: db6 wavelet, te funkcija skale i filtri za rekonstrukciju i dekompoziciju

Zbog toga što sustav za ekstrakciju značajki koji se koristi u ovom radu koristi DWT transformaciju, koja se svodi na filtarski slog, niskopropusni i visokopropusni filtri za dekompoziciju imaju oblik poput onog na slici 16.

4. Neuronska mreža

Povijest neuronskih mreža obilježilo je nekoliko ključnih ideja. 1943. godine američki znanstvenici Warren McCulloch i Walter Pitts uveli su teoriju neuronskih mreža kao specijalnih računala. Hebb je 1949. postulirao prvo pravilo učenja samoorganizirajućih mreža. Perceptron, model neuronskih mreža u kojem učenje implicira podršku (*eng. supervised learning*) i binarne izlaze, uveo je 1958. Frank Rosenblatt. U ovom poglavlju bit će pokriven kratak uvod u neuronske mreže, uz naglasak na osnovne koncepte: model neurona i Levenberg-Marquardt algoritam učenja, pošto su te tehnologije sastavni dio sustava koji je tema rada. Detaljnije informacijsko pokrće navedenih tehnologija je izvan opsega ovog rada.

4.1. Neuronske mreže

Od svojih idejnih začetaka, umjetne neuronske mreže bile su motivirane biološkim neuronskim mrežama. Biološki neuroni su po karakteristikama sporiji od digitalne logike, no mozak brzinu nadograđuje ogromnim brojem neurona (oko 10 milijardi neurona i 60 000 milijardi sinaptičkih spojeva). Mozak je usto i poprilično energetski efikasan (10^{-16} J po operaciji u sekundi, naspram 10^{-6} J po operaciji u sekundi). On je veoma kompleksno, nelinearno, paralelno računalo. Da bi uopće u mozgu bile moguća sofisticirana obrada informacija (bilo opažajnih, bilo introspekcijskih), potrebno je iskustvo, koje se gradi godinama. Sa iskustvom raste i broj sinaptičkih veza, koji je najaktivniji u prve dvije godine života (oko milijun sinapsi u sekundi). Sinapse omogućuju međuneuronsku interakciju, što predstavlja nužnu pozadinu procesa učenja. Presinaptički proces oslobađa tvar koja difundira kroz sinaptičku pukotinu i izaziva postsinaptički proces (Lončarić, 2010). Model piramidalnog neurona sa sinaptičkim ulazima i terminalima prikazuje slika 17. Dendriti, kako je moguće uočiti iz priloženog, imaju funkciju ulaza, odnosno primaju podražaje povezanih neurona. Akson prenosi podražaje prema sinaptičkim terminalima, koji su pak povezani s dendritima drugih neurona. Piramidalna živčana stanica može posjedovati i preko 10 000 ulaznih sinapsi, dok se njezin izlaz može prenijeti i na tisuće drugih neurona.


Prema popularnoj definiciji (Haykin, 1999), umjetne neuronske mreže mogu se opisati kao masivni paralelni distribuirani procesori sastavljeni od jednostavnih procesnih jedinica koje dobro pohranjuju iskustveno znanje, tako da je ono dostupno za upotrebu. Sličnost umjetnih neuronskih mreža s mozgom može se pronaći u dvjema karakteristikama:

- a) neuronska mreža formira znanje o okolini kroz proces učenja
- b) jakost međuneuronskih veza, odnosno sinaptičke težine, služe za pohranu znanja

Procedura koja odgovara procesu učenja u umjetnim neuronskim mrežama naziva se algoritam učenja. Njezina zadaća je modifikacija sinaptičkih težina mreže u svrhu postizanja željenog ponašanja. Neuronske mreže posjeduju sljedeća korisna svojstva i sposobnosti (Haykin, 1999):

- 1.) *Nelinearnost.* Umjetni neuron može biti linearan ili nelinearan. Neuronska mreža sastavljena od međusobno povezanih nelinearnih neurona je također nelinearna. Specijalnost nelinearnosti jest u distribuiranosti duž čitave mreže. Važnost tog svojstva evidentna je ukoliko je sustav koji generira ulazni signal inherentno nelinearan.
- 2.) *Preslikavanje ulaz-izlaz.* Kako će biti očito na primjeru mreže korištene u ovom radu, neuronska mreža uči na temelju uzoraka koji su joj dani konstruirajući ulazno-izlazno preslikavanje za dani problem. Takva paradigma učenja naziva se učenje s nadzorom.
- 3.) *Adaptivnost.* Neuronske mreže imaju ugrađenu sposobnost adaptacije sinaptičkih težina, ovisno o promjenama u okruženju. Ukoliko se radi o nestacionarnom okruženju, neuronska mreža može se dizajnirati tako da se njezine sinaptičke težine mijenjaju u stvarnom vremenu.
- 4.) *Odziv na evidenciju.* U kontekstu prepoznavanja uzoraka, neuronska mreža osim pružanja informacija o selekciji uzoraka nudi i informaciju o pouzdanosti odluke.
- 5.) *Otpornost na kvar.* Neuronska mreža mora biti implementirana tako da je inherentno otporna na greške u sustavu, u smislu da pri različitim oštećenjima spojeva ili funkcijskih jedinica zadrži željeni odziv. To se eventualno može odraziti na performanse sustava.

- 6.) *Mogućnost VLSI implementacije.* Priroda neuronskih mreža i njezina brzina u izvođenju koristeći paralelizme čine ju idealnim kandidatom za implementaciju vrlo visoko integriranim sklopovima (VLSI¹³).
- 7.) *Uniformnost u analizi i dizajnu.* U obradi informacija neuronske mreže posjeduju neka univerzalna svojstva. To znači da se identična notacija upotrebljava u svim domenama aplikacije. Neovisno o formi, neuroni su osnovni sastojak svih neuronskih mreža, što omogućuje izmjenu teoretske pozadine i algoritama za učenje u različitim primjenama. Modularne mreže mogu biti izgrađene besprijekornom integracijom modula.
- 8.) *Neurobiološka analogija.* Kao što je opisano u ranijim odlomcima, dizajn neuronskih mreža motiviran je analogijom s mozgom. To je ujedno i dokaz da je paralelna obrada podataka sa svojstvom otpornosti na kvar ne samo fizički moguća, već i brza, te izrazito moćna.



Slika 17: Piramidalni neuron¹⁴: 1. dendrit, 2. akson, 3. Ranvierova suženja, 4. terminalni završeci aksona, 5. mijelinska ovojnica, 6. tijelo neurona, 7. Jezgra


¹³ eng. *Very-large-scale-integrated technology*

¹⁴ http://hr.wikipedia.org/wiki/%C5%BDiv%C4%8Dano_tkivo

4.2. Model neurona

Neuroni su fundamentalne jedinice za obradu podataka u neuronskim mrežama. Model neurona kojeg prikazuje slika 18 tipičan je primjer često korištenog prototipa za izgradnju neuronske mreže koja rješava određen problem. Taj se model sastoji od triju osnovnih dijelova:

- sinapsi, odnosno ulaznih spojnica koje su otežane za neki faktor w_{kj} . Pritom k označava indeks neurona kojeg promatramo, a j jest indeks komponente ulaznog signala.
- zbrajalo otežanih ulaza. Rezultat je linearna kombinacija ulaza.
- nelinearna aktivacijska funkcija koja ograničava izlaz neurona na interval $[0,1]$ ili alternativno na $[-1,1]$



Slika 18: Model neurona

Model na slici 18 posjeduje i *bias*, odnosno prag, koji se označava sa b_k . Ovisno o tome je li pozitivan ili negativan, bias utječe na podizanje ili spuštanje mrežnog inputa aktivacijske funkcije.

Matematički, neuron k možemo opisati sljedećim jednažbama:

$$u_k = \sum_{j=1}^m w_{kj} x_j$$

$$y_k = \varphi(v_k) = \varphi(u_k + b_k)$$

Pritom $X = \{x_1, x_2, \dots, x_m\}$ predstavlja skup ulaznih uzoraka, $w_{k1}, w_{k2}, \dots, w_{km}$ su sinaptičke težine neurona k , u_k je linearna kombinacija ulaza, b_k bias, $\varphi(\cdot)$ predstavlja aktivacijsku funkciju, a y_k je izlazni signal neurona. Bias djeluje poput afine transformacije izlaza iz sumatora navedenog modela, odnosno:

$$v_k = u_k + b_k$$


Ovisno o predznaku i iznosu biasa, lokalno inducirano polje ili aktivacijski potencijal v_k se u odnosu na u_k relativno mijenja. Prisutnost praga može se prikazati kao dodatan ulaz iznosa +1 i težine b_k .

4.3. Aktivacijska funkcija *tansig*

Postoji širok spektar aktivacijskih funkcija φ koje se mogu koristiti u neuronskim mrežama, no u ovom radu se upotrebljava hiperbolična tangentna sigmoidna funkcija. Ta funkcija određuje iznos izlaza iz neurona ovisno o aktivaciji. Bazirana je na hiperboličnoj tangentnoj funkciji *tanh*, koja je preciznija, ali je njezin izračun sporiji. Razlike između *tansig* i *tanh* su neznatne, ali se odabire prva jer je u neuronskim mrežama to dobar *trade off* između brzine izvođenja i preciznosti. *tansig* se računa sljedećom formulom (tansig (Neural Network Toolbox)):

$$tansig(n) = \frac{2}{1 + \exp(-2n)} - 1$$

Pošto se ona sastoji od eksponencijalne funkcije i osnovnih algebarskih operacija, njezino izvođenje u MATLAB-u je brzo. Graf *tansig* funkcije prikazuje slika 19. Vidljivo je da funkcija vraća vrijednost u intervalu $[-1, 1]$.



Slika 19: Hiperbolična tangentna sigmoidna funkcija *tansig*

4.4. Levenberg-Marquardt algoritam učenja

Levenberg-Marquardt (skraćeno LM) algoritam učenja je iterativan algoritam koji pronalazi minimum funkcija više varijabli, najčešće izraženih preko sume kvadrata nelinearnih realnih funkcija. LM algoritam često se koristi za rješavanje problema najmanjih kvadrata, što ima svoju primjenu u širokom spektru ljudskih aktivnosti. Taj se algoritam može ilustrirati kao kombinacija metode najbržeg spusta i Gauss-Newtonove metode (modifikacija Newtonove metode za pronalaženje minimuma funkcije). Ukoliko je trenutno rješenje sustava koji je obuhvaćen LM algoritmom daleko od ispravnog, algoritam se ponaša poput metode najbržeg spusta, što implicira određenu sporost, ali i garanciju konvergencije. S druge strane, rješenje sustava blisko ispravnom rezultirat će ponašanju algoritma analogno Gauss-Newtonovoj metodi.

Neka je f funkcija koja vrši preslikavanje vektora parametara $\mathbf{p} \in \mathcal{R}^m$ u mjerni vektor $\hat{\mathbf{x}} = f(\mathbf{p})$, $\hat{\mathbf{x}} \in \mathcal{R}^m$. Inicijalno su dani su vektori \mathbf{p}_0 i \mathbf{x} , nakon čega algoritam teži pronalasku vektora \mathbf{p}^+ koji najbolje zadovoljava relaciju f , odnosno minimizira kvadratnu udaljenost $\epsilon^T \epsilon$, uz $\epsilon = \mathbf{x} - \hat{\mathbf{x}}$. Osnova LM algoritma leži u aproksimaciji f u susjedstvu od \mathbf{p} .

Za malenu vrijednost norme $\|\delta_p\|$, proširenje u Taylorov red vodi prema aproksimaciji:

$$f(\mathbf{p} + \delta_p) \approx f(\mathbf{p}) + \mathbf{J}\delta_p$$

gdje je \mathbf{J} Jakobijan $\frac{\partial f(\mathbf{p})}{\partial \mathbf{p}}$.

Dakle, LM algoritam započinje sa inicijalnom vrijednošću vektora \mathbf{p}_0 , nakon čega proizlazi niz vektora $\mathbf{p}_1, \mathbf{p}_2, \dots$, takav da algoritam konvergira prema lokalnom minimumu \mathbf{p}^+ funkcije f . Stoga je u svakom koraku potrebno pronaći vrijednost δ_p koja minimizira relaciju $\|\mathbf{x} - f(\mathbf{p} + \delta_p)\| \approx \|\mathbf{x} - f(\mathbf{p}) - \mathbf{J}\delta_p\|$. Navedena vrijednost δ_p stoga je rješenje linearnog problema najmanjih kvadrata, pošto je minimum postignut ako je $\mathbf{J}\delta_p - \epsilon$ vektor ortogonalan na stupce od \mathbf{J} . Ovaj zaključak se može zapisati matematičkom formulacijom $\mathbf{J}^T(\mathbf{J}\delta_p - \epsilon) = 0$, odnosno:

$$\mathbf{J}^T \mathbf{J} \delta_p = \mathbf{J}^T \epsilon$$

Matrica $\mathbf{J}^T \mathbf{J}$ je aproksimacija Hessianove matrice, odnosno matrice druge derivacije. LM algoritam u suštini rješava varijaciju problema iz gornje jednačbe, normalnu jednačbu:

$$\mathbf{N} \delta_p = \mathbf{J}^T \epsilon$$

gdje \mathbf{N} predstavlja matricu koja van dijagonale ima elemente jednake $\mathbf{J}^T \mathbf{J}$, dok se dijagonalni elementi izvode preko $N_{ii} = \mu + [\mathbf{J}^T \mathbf{J}]_{ii}$, uz $\mu > 0$.

Faktor μ se naziva faktorom prigušenja. Ukoliko u nekom koraku LM algoritma obnovljeni vektor $\mathbf{p} + \delta_p$ vodi prema redukciji pogreške ϵ , trenutno rješenje se prihvaća i sljedeći korak algoritma započinje sa umanjenim faktorom prigušenja. U protivnom se faktor prigušenja uvećava, ponovno se evaluira normalna jednačba, te se čitav proces iterira dok nije pronađena vrijednost δ_p koja umanjuje pogrešku. U LM algoritmu se faktor prigušenja u svakoj iteraciji ažurira tako da se uvijek osigura redukcija pogreške ϵ . Ako je μ blizak nuli, ovaj algoritam ponaša se poput Newtonove metode, koristeći aproksimaciju Hessianove matrice. Ako je pak μ velik broj, algoritam postaje metoda najbržeg spusta sa malim korakom.

Newtonova metoda brža je i preciznija oko minimuma pogreške, što opravdava potrebu za umanjivanjem faktora prigušenja nakon svakog uspješnog koraka (u realnim slučajevima, redukcije funkcije pogreške, npr. srednje kvadratne pogreške MSE¹⁵) i njegovim uvećavanjem u protivnom (The MathWorks, Inc., 2007).

U svojoj programskoj implementaciji, LM algoritam će stati ukoliko je zadovoljen jedan od sljedećih uvjeta (uz zadane vrijednosti pragova ϵ_1 , ϵ_2 , ϵ_3 i broja iteracija) (Lourakis, 2005):

- rješenje $\mathbf{J}^T \epsilon$ normalne jednadžbe je manje od praga ϵ_1
- relativna promjena u veličini δ_p je manja od praga ϵ_2
- pogreška $\epsilon^T \epsilon$ je manja od praga ϵ_3
- dosegnut je maksimalni broj iteracija

4.5. Parametri korištene mreže

Mreža koja se koristi u ovom radu sastoji se od tri „glasačka“ (*eng. voting*) neurona, odnosno tako treniranih neurona da je klasa uzorka na ulazu mreže određena indeksom neurona koji ima najveći izlaz. Takvo ponašanje djelomice podsjeća na kompetitivne neuronske mreže, s tim da ovakva mreža nema povratne veze. Svaki od tih neurona prima vektor dimenzije 64, te vraća broj ovisno o izlazu aktivacijske funkcije. Nakon učenja, ustanovljeno je da svaki od tih neurona posjeduje i bias. Parametri pojedinog neurona su:

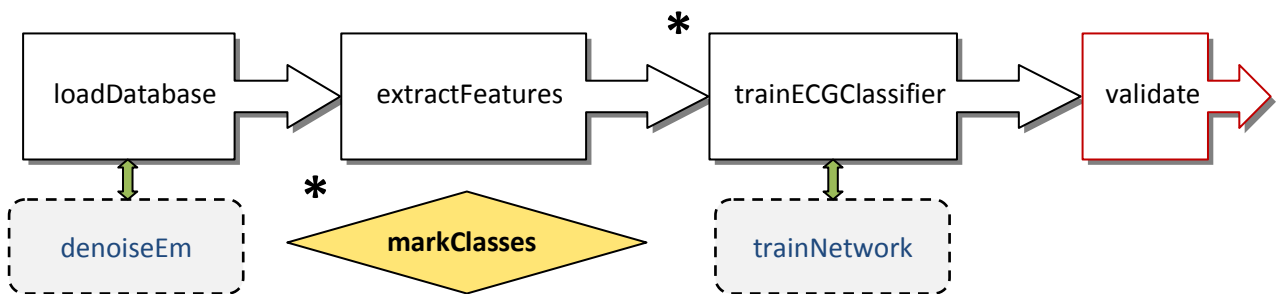
- hiperbolična tangenta sigmoidna aktivacijska funkcija (*tansig*)
- Levenberg-Marquardt algoritam učenja
- funkcija pogreške je srednja kvadratna pogreška MSE
- faktor učenja $lr = 0.99$
- maksimalan broj iteracija je 300.000
- ciljana vrijednost pogreške pri učenju je 0.0001

¹⁵ *eng. Mean Squared Error*

5. Opis klasifikatora srčanih ritmova

Ostvarenje klasifikatora ne bi bilo moguće da prethodno nisu kreirane komponente za trening neuronske mreže. Stoga se sustav koji je tema ovog rada sastoji od dvaju cjelina: podsustava za učenje neuronske mreže i samog klasifikatora koji radi uz pomoć mreže.

Proces učenja neuronske mreže ostvaren je interakcijom komponenti izgrađenih u MATLAB-u. Njihova interakcija opisana je u dijagramu na slici 20.



Slika 20: Dijagram podsustava za trening neuronske mreže i njenu validaciju

Navedene komponente su ujedno i istoimene MATLAB funkcije (ekstenzija .M). U narednim potpoglavljima bit će opisan njihov rad, što će ujedno i razjasniti tijek dijagrama na slici 20. Na kraju poglavlja nalaze se upute za trening neuronske mreže.

5.1. Komponente sustava, opis metoda

5.1.1. loadDatabase.m

Funkcija *loadDatabase.m* poziva se na sljedeći način:

```
>> [S, HRS] = loadDatabase('Data');
```

gdje „Data“ predstavlja relativnu poziciju direktorija u kojem se nalaze EKG signali (argument funkcije).

Ona vraća dvije strukture: učitane uzorke *S* i prosječne vrijednosti broja otkucaja za pojedine uzorke *HRS*. Prvotno funkcija vrši popisivanje poddirektorija unutar zadanog direktorija. Potom se za svaki poddirektorij vrši popisivanje datoteka koje se nalaze unutar njih.

Te datoteke predstavljaju čitave EKG signale, čije su karakteristike opisane u poglavlju 2.3. Funkcija iterira po svakoj od tih datoteka, te vrši prijevod istih u MATLAB-u znan matrični format. To omogućuje metoda *rdsamp()*, koja dolazi uz WFDB *plugin*. Ona se poziva sa *rdsamp(record, ...)*, gdje „record“ označava naziv EKG zapisa bez ekstenzije (predan kao niz znakova, dakle sa ' delimiterom). EKG zapisi nakon prijevoda u matrični format imaju dimenziju [*duljina_EKG_zapisa* X 3], no za potrebe analize se odabiru odvodi V1 i II i spremaju u temporalnu varijablu. Iz svih odvoda uklonjena je istosmjerna komponenta (*DC offset*). Potom se tako pohranjen EKG zapis segmentira na 20 okvira od kojih je svaki dugačak $20 \cdot f_s$ jedinica, pri čemu f_s predstavlja frekvenciju otipkavanja EKG signala pri digitalizaciji. Okviri se uzimaju od desete minuta EKG zapisa, pošto se empirički pokazalo da nakon od tog vremena svi signali pokazuju najmanje oscilacije zbog stranih čimbenika. Svaki okvir filtriran je specijalnim wavelet filtrom kako bi se uklonio šum, što obavlja metoda *denoiseEm.m*. O njoj će biti govora u narednom potpoglavlju. U pročišćenim okvirima se potom vrši lociranje *R* zubaca kako bi se iz okvira izdvojilo fiksno sedam otkucaja srca, što je izvedeno putem naredbe *findpeaks()* koja će vratiti indekse onih vršnih vrijednosti signala koji zadovoljavaju određeni uvjet. U ovom slučaju, radi se o pragu koji mora zadovoljiti svaki ekstrem (iznosi 100 jedinica). Tih sedam impulsa iz pojedinog okvira predstavlja jedan uzorak za učenje neuronske mreže. Paralelno sa izdvajanjem *R* zubaca, u zasebnu varijablu se pohranjuju i

prosječne vrijednosti broja otkucaja srca za svaki okvir. Taj čimbenik se izračunava na temelju sljedeće relacije:

$$HR = \frac{60}{RR}$$

gdje je RR udaljenost između dva uzastopna R zupca. Ovaj sustav izračunava prosječnu udaljenost između zubaca u okviru, dijeli taj broj sa frekvencijom otipkavanja kako bi se dobio izraz u sekundama, te potom prosječnu RR vrijednost množi sa 60.

Prije no što se navedeni podaci konačno pohrane u matricu uzoraka za učenje S , svaki uzorak se sažima ili proširuje (ovisno o trajanju) na vrijednost od 1500 jedinica.


5.1.2. denoiseEm.m

Ova metoda služi za uklanjanje šuma iz signala, te se sastoji od poziva dviju MATLAB-funkcija:

```
[thr,sorh,keepapp]=ddencmp('den','wv',x);  
  
[y,cxc,lxc,perf0,perf12]=wdencmp('gbl',x,'db6',8,thr,sorh,keepapp);
```

Prvi poziv, *ddencmp()* vratit će redom pogodnu vrijednost praga, odluku o grubom ili blagom filtriranju s obzirom na prag, te indikaciju o čuvanju aproksimacijskih koeficijenata. Argumenti 'den' i 'wv' označavaju da se radi o *wavelet denoising* opciji, odnosno uklanjanju šuma uz pomoć waveleta.

wdencmp() uklanja šum iz signala x ne temelju danih parametara. Izuzev već spomenutih *thr*, *sorh* i *keepapp*, dodatni parametri su 'gbl' ili postavka globalnog praga i 'db6' koji implicira odabir Daubechies 6 waveleta kao osnovnog waveleta pri filtriranju. Filtrirani signal sprema se u y . Ilustraciju uklanjanja šuma filtarskim slogom prikazuje slika 21.



Slika 21: Ilustracija procesa eliminacije šuma iz EKG zapisa wavelet dekompozicijom

5.1.3. `extractFeatures.m`

Jezgru sustava čini metoda za ekstrakciju značajki pošto reducira uzorke na jednodimenzionalne vektore duljine 64 u kojima je sadržana informacija koja omogućuje distinkciju različitih razreda uzoraka. Ekstrakcija značajki u `extractFeatures()` ostvaruje se wavelet dekompozicijom uzoraka u 8 razina (skala), kako je to objašnjeno u poglavlju 3. Dekompozicija se vrši ugrađenom MATLAB funkcijom `wavedec()`, ponovno pomoću db6 waveleta. Na svakoj razini dekompozicije mogu se očitati aproksimacije i detalji. Stoga je za svaki uzorak na raspolaganju 16 wavelet komponenti. Za svaku od wavelet komponenti izračunavaju se naredne značajke:

- Varijanca
- Maksimalna vrijednost
- Minimalna vrijednost
- Srednja vrijednost

Tako određenim značajkama dimenzije vektora značajki postaju evidentne ($2 \times 8 \times 4$).


5.1.4. `markClasses.m`

Da bi neuronska mreža izvršila procjenu funkcije preslikavanja ulaz-izlaz, potrebna joj je informacija o pripadnosti klasama za svaki od uzoraka. Pošto EKG zapisi različitih pacijenata ne pokazuju identično ponašanje tokom vremena, pogodnije je ručno klasificirati uzorke no pretpostaviti da svi uzorci unutar jedne datoteke pripadaju istom razredu. `markClasses()` će za dani skup uzoraka S prikazati dva grafa (II i V1), nakon čega je korisnik dužan označiti promatrani uzorak brojem u rasponu [1,3] po svojoj procjeni viđenog. Broj '1' označava pripadnost uzoraka prvom razredu, LBBB, broj '2' normalnom srčanom ritmu, a broj '3' RBBB.

5.1.5. `trainECGClassifier.m`

Nakon što su ekstrahirane značajke EKG uzoraka za učenje i pripremljena korespondentna matrica pripadnosti klasama (zadatak metode `markClasses.m`), moguće je trenirati neuronsku mrežu koja će služiti kao klasifikator novih, testnih uzoraka. Metoda `trainECGClassifier.m` prima polje značajki, matricu klasa i informaciju o broju klasa. Potom se vrši trening onoliko neurona koliko je razreda, tako da svaki neuron mora dati pozitivan izlaz samo za po jedan razred, a ničticu za ostale. To znači da će u praktičnim primjenama svaki neuron za određenu klasu dati veći broj, a za ostale manji. Primjerice, ukoliko je broj razreda 3 (kao što je slučaj u ovom radu), onda se prvi neuron može trenirati tako da za sve uzorke prvog razreda željeni izlazi d budu 1, a za uzorke ostalih razreda 0. Drugi neuron će se trenirati tako da uzorcima drugog razreda odgovara odziv 1, a ostalima odziv 0.

Analogno vrijedi i za treći neuron. Taj postupak ilustrira slika 22. Valja napomenuti da se svaki od neurona trenira funkcijom `trainNetwork.m`.



Slika 22: Primjer treniranja uzorkom iz prvog razreda

5.1.6. `trainNetwork.m`

U ovoj metodi nalaze se svi parametri za treniranje neuronske mreže (odnosno neurona u ovom slučaju) korištenjem Neural Network Toolboxa, koji je dio MATLAB-a. Parametri potrebni za izgradnju i trening mreže su:

- skup uzoraka za učenje
- matrica korespondentnih klasa
- tip aktivacijske funkcije
- algoritam učenja
- funkcija pogreške
- faktor učenja
- maksimalni broj iteracija
- ciljana vrijednost pogreške

Ukoliko su svi parametri spremni za predaju, `trainNetwork()` će inicijalizirati mrežu i započeti njen trening. Proces traje dok nije postignuta zadovoljavajuća vrijednost greške izračunate na temelju funkcije pogreške.

5.1.7. validate.m

Metoda *validate()* prima skup treniranih neurona, značajke uzoraka koje valja validirati/klasificirati, te matrice klasa. Pri završetku izvođenja, ova će metoda vratiti odzive svih neurona i pripadnu točnost umjetne klasifikacije danih uzoraka na temelju njihovih značajki. Odluka o klasi vrši se tako da je indeks klase jednak indeksu neurona koji je dao maksimalan odziv (usporediti opis funkcije *trainECGClassifier()*). Ova metoda ujedno se koristi i u sučelju EKG klasifikatora.

5.2. Proces učenja neuronske mreže

Tijek procesa učenja čine sljedeći koraci:

1.) učitavanje skupa za učenje naredbom *loadDatabase()*:

```
>> [S, HRS] = loadDatabase('lokacija baze');
```

2.) učitavanje skupa za testiranje naredbom *loadDatabase2()*:

```
>> [T, HRT] = loadDatabase2('lokacija baze');
```

3.) ekstrakcija značajki za oba skupa:

```
a) >> SF = extractFeatures(S, 'db6'); %koristimo db6 wavelet
```

```
b) >> TF = extractFeatures(T, 'db6');
```

4.) Ručno označavanje pripadnosti klasama za oba skupa:

```
a) >> C = markClasses(S);
```

```
b) >> D = markClasses(T);
```

5.) treniranje neuronske mreže za tri razreda:

```
>> Nets = trainECGClassifier(SF, C, 3);
```

6.) pohrana trenirane mreže u datoteku *Nets.mat* za eventualno kasnije korištenje putem sučelja:

```
>> save('Nets.mat', Nets);
```

7.) validacija skupa za testiranje:

```
[rezultatiMreze, tocnost] = validate(Nets, TF, C, D);
```

Pregledom varijable *točnost* i odziva mreže u *rezultatiMreze* moguće je ocijeniti kvalitetu učenja. Naravno, valja uzeti u obzir kontekst u kojem se odvijalo učenje, odnosno reprezentativnost skupa uzoraka za učenje i testiranje u odnosu na realne situacije.

6. Grafičko sučelje

6.1. Radna okolina

Za svrhe razvijanja i testiranja funkcionalnih procedura koji čine okosnicu klasifikatora korišten je programski paket MATLAB u svojoj inačici 7.7.0 (R2008b) na platformi Windows XP Professional Edition. Preporučena konfiguracija za testiranje grafičkog sučelja i evaluaciju procesa učenja je:

OS: Windows XP SP3 / Windows Vista / Windows 7

Memorija: min. 1 GB RAM

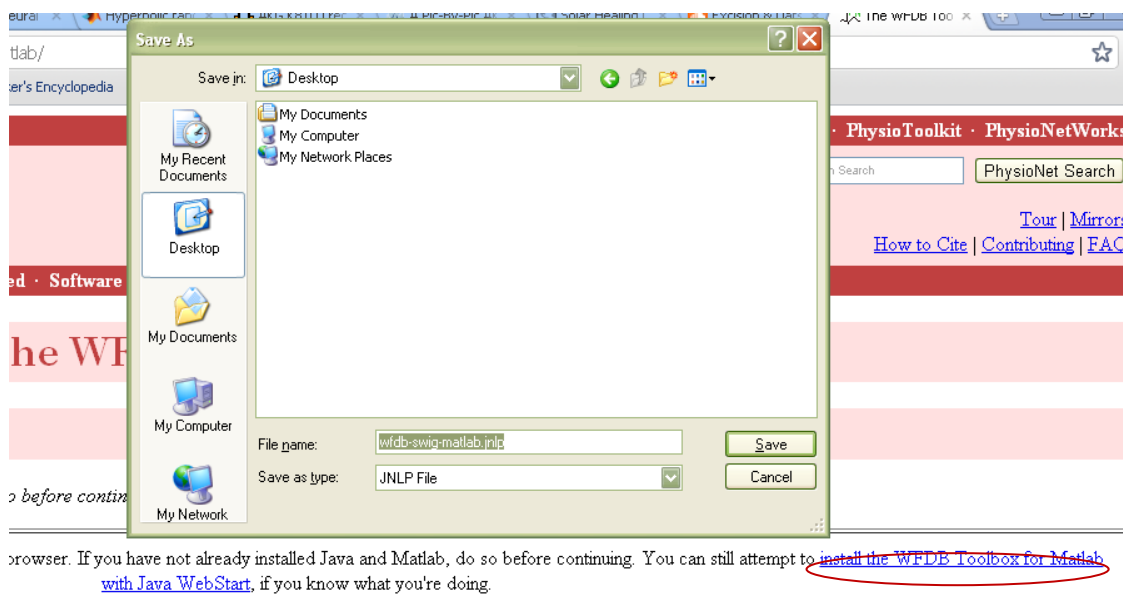
Procesor: preporučljivo barem 1 GHz procesorskog takta

Ostalo: MATLAB 7 (od R14 nadalje), Java 6, dostupnost Interneta

6.2. Softverski paket WFDB

Klasifikator opisan u ovoj dokumentaciji oslanja se na WFDB *plugin* koji omogućuje konverziju EKG zapisa iz različitih medicinskih formata u MATLAB-ov matrični format. Stoga je prije testiranja aplikacije potrebno instalirati *plugin*, na sljedeći način:

- spojiti se na Internet i posjetiti stranicu
<http://www.physionet.org/physiotools/matlab/wfdb-swig-matlab/>
- kliknuti na link „install the WFDB Toolbox for Matlab with Java WebStart“, te spremiti odgovarajuću datoteku negdje na disk (alternativno, desni klik i „Save Target As“) (slika 23)
- pokrenuti instalacijsku datoteku „wfdbswigmatlab.jnlp“ dvoklikom na nju (potrebno je osigurati postojanost Java Runtime okruženja, od verzije 6 nadalje)
- pratiti instalacijske upute, te instalirati paket u MATLAB-ov direktorij
- pri završetku instalacije dopustiti testiranje *plugina*



Slika 23: Pohrana instalacijskog paketa WFDB *plugina*

6.3. Grafičko sučelje

Grafičko sučelje klasifikatora, *ECG Classifier*, dizajnirano je u razvojnoj okolini *GUIDE*, koja je dio programskog paketa *MATLAB*. *GUIDE* nudi jednostavan i intuitivan pogled u shemu sučelja, u kojoj je moguć direktan vizualni uvid u konačan produkt (*WYSIWYG*¹⁶). Da bi se pokrenuo *ECG Classifier* potrebno je otvoriti *MATLAB*, pozicionirati se u direktorij u kojem se nalaze datoteke koje su priložene uz ovaj rad (na CD-u) i ukucati:

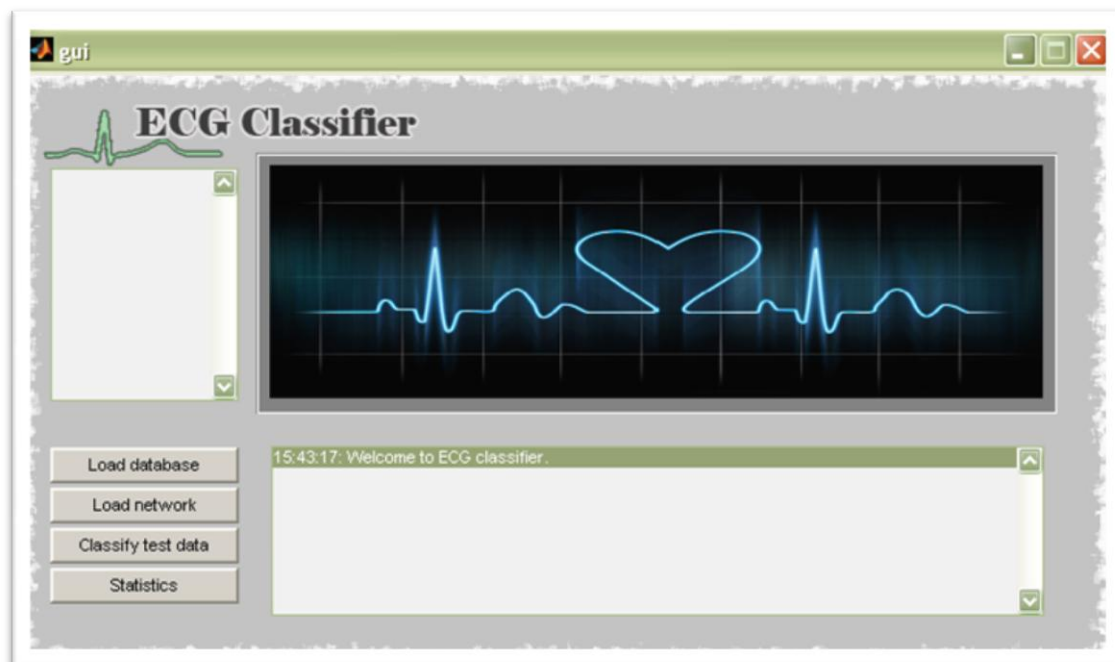
```
>> gui [ENTER]
```

Nakon toga će se otvoriti prozor poput onog na slici 24. Aplikacija se sastoji od četiri segmenta: liste uzoraka (taj prozor ujedno služi i kao uvid u ispravnost klasifikacije i prikaz željenog uzorka), graf uzorka, polje opcija, te konzolni prozor sa nekim osnovnim informacijama (slično poput *log* prozora u engleskim sučeljima).

¹⁶ eng. *What You See Is What You Get*

Pregledom polja opcija, vidljivo je da su moguće četiri akcije:

- *Load database* – odabirom ove opcije otvorit će se prozor u kojem valja odabrati direktorij gdje se nalaze uzorci koje želimo klasificirati. Nakon odabira, prikazat će se indikacijska traka koja pokazuje proces unosa podataka u memoriju. Nakon što je učitavanje gotovo, na sučelju će se ocrtati popis svih (nerazvrstanih) EKG uzoraka, te će biti prikazan graf prvog učitano uzorka, no fokus na neki drugi EKG uzorka je također moguć pritiskom na ini. Uz sam graf priložena je i informacija o prosječnom broju otkucaja (*HR* faktor).
- *Load network* – odabirom ove opcije vrši se odabir prethodno trenirane neuronske mreže, pohranjene u datoteku ekstenzije *.MAT*.
- *Classify test data* – glavna je funkcija sučelja; ona vrši klasifikaciju prethodno odabranih uzoraka pomoću učitane mreže. Pritiskom na dugme uzorci prolaze kroz dvije procedure: prvo se vrši ekstrakcija značajki, a onda se evaluira mreža. Tijek obje procedure popraćen je indikacijskom trakom. Pri završetku klasifikacije, u kućici s popisom EKG uzoraka će zelenu boju poprimiti oni koji su ispravno, a crvenu oni koji su neispravno klasificirani.
- *Statistics* – nakon što su svi uzorci klasificirani, odabirom ove opcije moguće je vidjeti statističke podatke u *pie chart* formi, ovisno o kategoriji (slika 25).



Slika 24: Početno stanje programa *ECG Classifier*



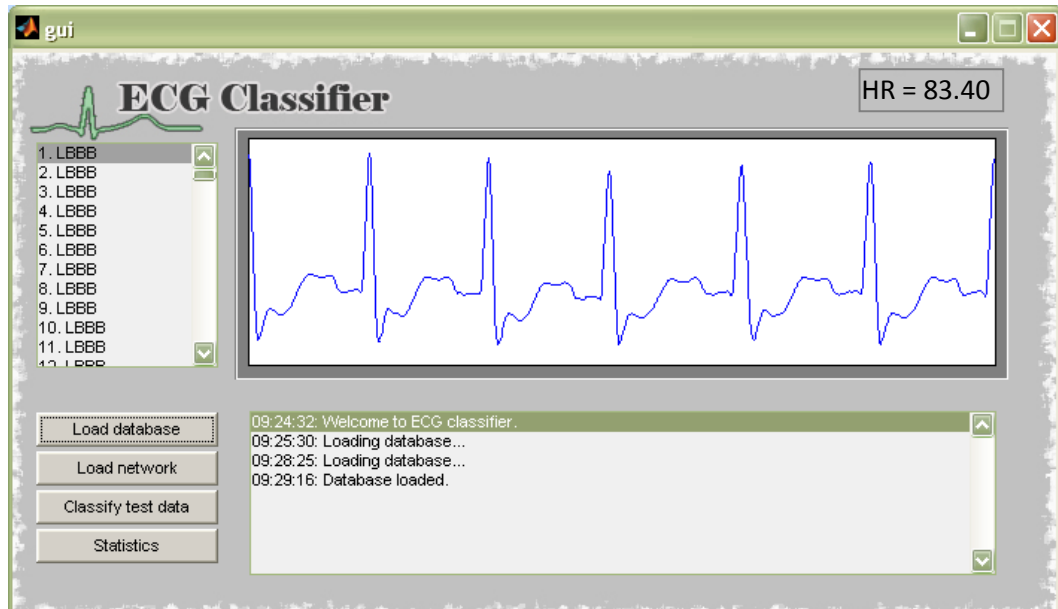
Slika 25: Statistička analiza pokrenuta iz sučelja

Važno je napomenuti da je za ispravan rad aplikacije ključno birati opcije onim redoslijedom kojim su postavljene u aplikaciji, s tim da za elementaran rad mora biti izvršen barem prvi korak, tj. učitavanje baze. Dakle, moguće je opetovano učitavanje različitih neuronskih mreža i ponovna klasifikacija na temelju iste, uz obnovu statističkih podataka.

Izlazak iz aplikacije vrši se na klasičan način, pritiskom na „X“ u gornjem desnom dijelu aplikacije.

6.3.1. Primjer rada aplikacije

Nakon pokretanja grafičkog sučelja naredbom *gui* u MATLAB-u i statusnog ekrana kao na slici 24, korisnik može započeti sa učitavanjem prostora uzoraka kako bi ih pripremio za proces ekstrakcije. To se ostvaruje odabirom opcije *Load database* nakon čega ekran ima oblik poput onog na slici 26:




Slika 26: Izgled sučelja nakon učitavanje baze pacijenata

Učitavanje se vrši na način analogan opisu funkcije *loadDatabase.m*.

U lijevom odjeljku sučelja prikazat će se popis *a priori* klasa po svakom učitanoj uzorku. Svaki element iz liste uzoraka moguće je selektirati, što će rezultirati ispisom sedam impulsa na desni dio ekrana, u formi grafa. Uz to je vidljiv i prosječan broj otkucaja kao *HR* faktor. Primjer iz slike 26 prikazuje prvi, automatski selektirani uzorak koji se odnosi na klasu „blokada lijevog provodnog bloka“ (engleska skraćenica *LBBB*). U gornjem desnom dijelu ekrana ispisan je *HR* faktor.

Uz navedene mogućnosti, sučelje nudi i uvid u vremenski razvoj procesa. Sve operacije koje iziskuju nešto veće vrijeme izračuna imaju indikacijsku traku kako bi se korisniku obznanio tijek obrade. Indikacijske trake vidljive su za operacije: učitavanje, ekstrakcija značajki i klasifikacija. Indikacijsku traku za proces učitavanja baze prikazuje slika 27.

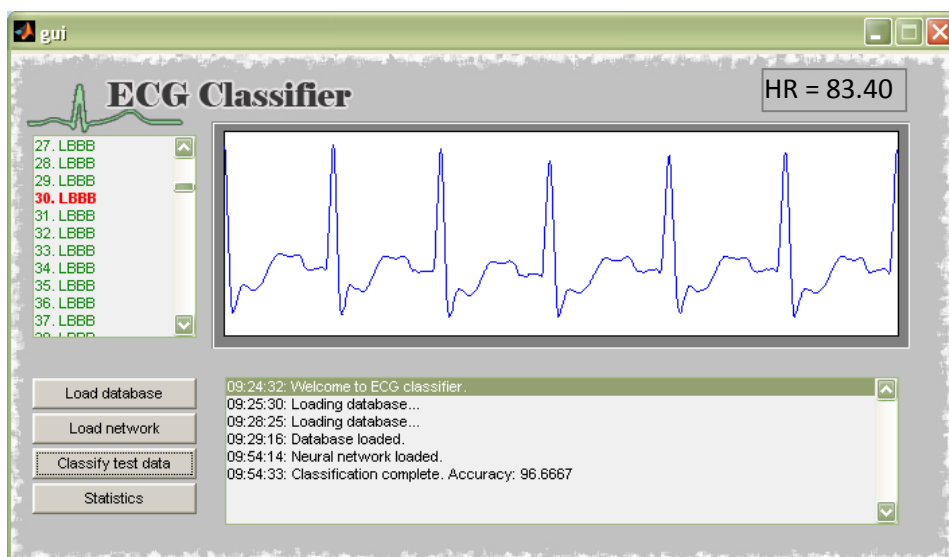


Slika 27: Indikacijska traka za proces učitavanja baze

Izuzev indikacijske trake, korisniku je vidljiva i informacija o uspješnosti operacije i njezinom trajanju, putem informacijskog okvira u donjem desnom dijelu sučelja. Svaka operacija ima svoju vremensku etiketu, pa je tako iz slike 26 vidljivo da je proces učitavanja imao trajanje od otprilike 41 sekundu.

Nakon učitavanja baze slijedi učitavanje trenirane neuronske mreže (proces treniranja objašnjen je u potpoglavlju 5.2.). Navedena opcija je na sučelju naznačena kao *Load network*. Ona u suštini poziva MATLAB naredbu *load()* nad datotekom koju je ručno označio korisnik, a koja ima ekstenziju *.MAT* (npr. „Nets.mat“). Pri završetku učitavanja mreže, informacijski okvir osvježit će sadržaj i izvijestiti o uspješnom učitavanju mreže.

Sljedeći korak jest ekstrakcija značajki i klasifikacija putem opcije *Classify test data*. Odabirom ove opcije uzorci koji su lokalno učitani u memoriju, a popisani su na listi proći će kroz wavelet dekompoziciju u osam razina (db6 waveletom kako je opisano u poglavlju 5), ekstrakciju značajki na svakoj od tih razina, te, konačno, klasifikaciju preko funkcije *validate()*. Ta dva glavna procesa popraćena su pripadnim indikacijskim trakama i spadaju pod procese *extractFeatures()* i *validate()*. Pri završetku obrade, prozor će izgledati slično kao na slici 28.



Slika 28: Izgled sučelja pri završetku procesa ekstrakcije značajki i klasifikacije

Iz slike 28 vidljivo je da se u informacijskom okviru javlja informacija o točnosti klasificiranih uzoraka. U ovom slučaju ona je jednaka oko 96.7%. Uzorci koji su ispravno označeni će u listi uzoraka za prikaz biti obojani zelenom, a neispravno klasificirani uzorci crvenom bojom. Korisnik u ovom trenutku može još eventualno pokrenuti statistički graf opcijom *Statistics*, što će rezultirati ekranom sličnim onim na slici 25.

6.4. Mogući problemi u radu

Kao što je spomenuto, za osnovnu funkcionalnost aplikacije baza EKG uzoraka mora biti ispravno učitana. Direktorij u kojem se nalaze uzorci mora biti u relativnom odnosu naprama glavnom direktoriju gdje se nalaze ostale datoteke. To znači da ukoliko je primjerice čitav sustav pohranjen u „C:\Test“, tada baza mora biti ili u tom direktoriju ili u nekom od poddirektorija, npr. „C:\Test\Baza“.

Izuzev eventualnih problema s neispravnim učitavanjem baze, moguć je indirektan problem sa *pluginom* WFDB. Naime, ta ekstenzija omogućuje i učitavanje EKG-a određenog pacijenata preko PhysioBank servera, s tim da je sintaksa učitavanja lokalnog i serverskog uzorka ista. To može biti problematično ukoliko je PhysioBank server neaktivan, a računalo na kojem se pokreće *ECG Classifier* spojeno na Internet, pošto će WFDB *plugin* prvo provjeriti stanje PhysioBank servera a onda lokalne datoteke. Dakle, moguć je zastoј sve dok server nije dostupan. U tom slučaju, najbolje je isključiti vezu s Internetom pa će *plugin* pristupati samo lokalnim datotekama.

7. Statistički podaci i analiza uspješnosti

Za svrhe testiranja kvalitete klasifikacije izgrađenog sustava za raspoznavanje triju klasa EKG-a, upotrijebljen je korpus od 20 pacijenata iz MIT-BIH baze spomenute u potpoglavlju 2.4. Ti su pacijenti ručno označeni od strane medicinskog osoblja, te je stoga bilo moguće izdvojiti ih u zasebne direktorije sa svrhom lakšeg dohvata u razvojnom okruženju MATLAB. Iako su dotični pacijenti ručno označeni u tri kategorije (normalan srčani ritam, blokada lijevog i desnog provodnog bloka), analiza segmenata pojedinih zapisa (koji čine prostor uzoraka) pokazala je da se dotični segmenti ne mogu *a priori* pretpostaviti kao pripadnici klase ovisno o tome je li čitav EKG označen jednoznačno. To ima i svoju logičku poveznicu s obzirom na raspravu o kritičnoj frekvenciji srca, pošto do blokade desnog (češće) i lijevog provodnog bloka može doći i u pacijenata koji ne pokazuju znakove permanentnog patološkog poremećaja. Dakle, svi segmenti izdvojeni iz datoteka pacijenata dodatno su ručno pregledani grafovima I i V1 i shodno odluci označeni (metoda `markClasses()`). Uzorci za testiranje dijele se u dvije skupine: prvu skupinu čine uzorci pacijenata s kojima je vršeno i učenje neuronsko mreže, ali se oni sadržajno razlikuju jer su izdvojeni iz drugih vremenskih intervala. Valja napomenuti da kod takvih uzoraka ujedno dolazi i do pomaka izmjenične komponente smetnje, tako da su i oni zadovoljavajuće reprezentativni za proces testiranja. Drugu skupinu uzoraka čine pacijenti koji nisu pripadali skupini koja je uključena u proces učenja. Razlog ovakvoj podjeli je u ograničenom broju uzoraka za klase 1 i 3, odnosno pacijenata sa blokadom lijevog i desnog provodnog bloka. Unatoč toj činjenici, autor ima razloga zaključiti da je mreža relativno kvalitetno naučila funkciju preslikavanja s obzirom na razred, što i pokazuje statistika.

Tablica 1 prikazuje proces mjerenja točnosti za prvi razred uzoraka. Radi se o 180 uzoraka od po sedam impulsa koji su skalirani na fiksni vremenski okvir. Nakon ekstrakcije polja značajki, dobiva se matrica značajki čiji reci predstavljaju uzorak reprezentiran statističkim podacima iz wavelet koeficijenata (njih 64). Ta matrica dovodi se na ulaz trenirane neuronske mreže. Rezultati neuronske mreže pokazuju da u prvoj klasi uzoraka, onoj koja se odnosi na blokadu lijeve provodne grane, nalazimo točnost od oko 93% ispravno klasificiranih uzoraka. U drugoj klasi oko 97%, te u trećoj klasi 100% ispravno klasificiranih.

Klasa	Ukupan broj uzoraka	Broj točno klasificiranih uzoraka
Blokada lijeve provodne grane	60	56
Normalan srčani ritam	60	58
Blokada desne provodne grane	60	60
	Σ 180	Σ 174

Tablica 1: Statistika prvog mjerenja

Drugo mjerenje, nešto reprezentativnije u praktičnom pogledu, pokazuje točnost od oko 90.2% za prvi razred, 92% za drugi, te 87% za treći razred uzoraka. Pritom je testirano ukupno 200 uzoraka, na način prikazan u tablici 2. Udio točno klasificiranih uzoraka za pojedinu klasu u oba mjerenja prikazuju slike 29 i 30. Ukupna točnost za sve uzorke prvog razreda je 96.7%, a za druge 90.5%.

Klasa	Ukupan broj uzoraka	Broj točno klasificiranih uzoraka
Blokada lijeve provodne grane	61	55
Normalan srčani ritam	108	99
Blokada desne provodne grane	31	27
	Σ 200	Σ 181


Tablica 2: Statistika drugog mjerenja

Mjerenje	Točnost
I	96.7%
II	90.5%


Tablica 3: Točnost klasifikacije po mjerenju

Tablica 3 prikazuje ukupno točnost u svakom mjerenju, koja je shodno očekivanjima nešto viša za prvu skupinu uzoraka (96.7%).

Izračunom ponderiranog prosjeka dolazi se do točnosti od oko 93.33%.



Slika 29: Ispravno klasificirani uzroci u prvom mjerenju (postotak u odnosu na ukupan broj točno klasificiranih uzoraka, a ne u odnosu na ukupan broj danih uzoraka)



Slika 30: Ispravno klasificirani uzroci u drugom mjerenju (postotak u odnosu na ukupan broj točno klasificiranih uzoraka, a ne u odnosu na ukupan broj danih uzoraka)


Za vrijeme procesa učenja i validacije, primijećeni su varijabilni rezultati neuronske mreže kao klasifikatora. Zaključeno je da paket za trening neuronskih mreža, koji dolazi s MATLAB-om, ima pseudoslučajno ponašanje, te da stoga proces učenja nije fiksni, već ovisi o mnogo faktora (računalni resursi, nedeterministički postupci ubrzavanja učenja i sl.). Tablica 4 pokazuje razlike u točnosti klasifikacije s obzirom na pokušaje treninga.

	Prvi trening	Drugi trening	Treći trening
Točnost klasifikacije	90.1%	96.7%	95%

Tablica 4: Točnost klasifikacije s obzirom na trening neuronske mreže

U konačnici je odabrana ona mreža koja je dala najbolje rezultate.

Provedena je i analiza vremenskog izvođenja procesa učitavanja baze. Taj proces konzumira najviše računalnih resursa. Vrijeme izvođenja s obzirom na broj uzoraka prikazuje slika 31. Razlog nešto dulje izvođenja tog procesa leži u činjenici da on uključuje najviše operacija nad samim signalima: učitavanje iz datoteke, segmentaciju, predobradbu, izdvajanje impulsa, mjerenje *HR* faktora itd.



Slika 31: Vrijeme izvođenja procesa učitavanja baze, s obzirom na broj uzoraka (u sekundama)

Rezultate klasifikatora moguće je dodatno poboljšati uvođenjem opsežnije baze podataka, što autoru nije bilo na raspolaganju. Naime, spomenutih 20 pacijenata (besplatno preuzetih za PhysioBank portala) kvalitativno je označeno u tri klase, no uvidom u samu narav uzoraka vidljivo je da mnogi uzorci posjeduju značajan šum, što dodatno otežava uspješnu automatsku klasifikaciju i proces učenja. Pri izradi priloženog sustava vođena je briga o što preciznijem pregledu odvoda II i prekordijalnog odvoda V1. Specifični EKG obrasci vidljivi su na oba odvoda, ovisno o klasi, no prisutnost jakog šuma otežala je analizu pripadnosti klasama u nekih uzoraka. Šumoviti uzorci ujedno utječu i na veće oscilacije u vektoru značajki. Razlog tome je manji stupanj korelacije šumovitog uzorka sa Daubechies db6 waveletom. Pri izdvajanju sedam impulsa korišten je fiksni prag za R-valove, kako bi se locirao svaki

impuls, te izdvojio okvir za analizu u daljnjim koracima. Značajke izdvojene iz wavelet domene pokazuju se kao zadovoljavajuće, a neuronska mreža kvalitetno preslikava reprezentativne (manje šumovite) uzorke. Izuzev većeg broja pacijenata u bazi, bolju ocjenu pripadnosti određenoj klasi omogućila bi i dostupnost drugih EKG odvoda, naročito odvoda V6, koji u kombinaciji sa V1 daje dobru informaciju o blokadi lijevog ili desnog provodnog bloka.

Valja ponoviti da dizajnirani sustav putem sučelja ili komandnog prozora MATLAB-a prikazuje i informaciju o prosječnoj frekvenciji otkucaja, ekstrahiranoj na temelju prosječne udaljenosti R-valova u uzorcima. Ta je informacija, kako je ranije spomenuto, značajna jer omogućuje neke pretpostavke sa svrhom predikcije oboljenja. Pregledom niza prosječnih frekvencija koji prethode promatranom uzorku u sučelju sustava, korisnik može uvidjeti da li se radi o mogućem pomaku prema kritičnoj frekvenciji. Ukoliko je taj niz rastući, postoji realna mogućnost da srce pacijenta etiketiranog od strane stručnog osoblja u MIT-BIH korpusu za promatrani segment stupa u blokadu lijeve ili desne provodne grane.

Iz navedenih konstatacija može se zaključiti da prostor za kompleksniju razradu problema postoji, ali je i evidentno da dosadašnja implementacija pokazuje sasvim zadovoljavajuće rezultate s obzirom na kontekst.

8. Zaključak

U ovom radu prezentiran je sustav za automatsku klasifikaciju EKG signala u klase: normalan srčani ritam, blokada lijevog provodnog bloka, te blokada desnog provodnog bloka. Uz ekstrakciju značajki pomoću wavelet dekompozicije db6 waveletom izvršen je trening neuronske mreže, te su izvedeni testovi kako bi se utvrdila točnost klasifikacije. Statistička analiza pokazala je zadovoljavajuće rezultate iz oba primijenjena skupa uzoraka. Iako baza pacijenata kojom je raspolagao izgrađeni klasifikator nije bila opsežna, omogućila je uvid u mogućnosti na području medicinske dijagnostike.

Ovaj rad pokazuje da medicina i obradba informacija mogu funkcionirati u harmoničnom skladu. Posve je začuđujuće da unatoč tako naglom razvoju elektroničkih uređaja nakon industrijske evolucije nisu uloženi veći napor na području suradnje medicinskog osoblja i računalnih stručnjaka. Financijski aspekt nije opravdan, jer kao što pokazuje ovaj rad, tehnike poput diskretne wavelet transformacije i neuronskih mreža mogu se implementirati i sa najosnovnijim računalnim resursima. Neuronske mreže, danas već poprilično raširen aparat za izgradnju automatiziranih klasifikatora i detektora određenih uzoraka, u svojoj prilično jednostavnoj varijanti ovdje pokazuju svoju snagu. Statistička obrada nad testnim uzorcima EKG zapisa daje informaciju da je otvoren prostor za razradu problema automatske dijagnostike, no da to ujedno iziskuje i dodatne kako vremenske, tako i digitalne resurse. Perspektivno, moguće je zamisliti da se naprednija i kompaktnija (eventualno i sklopovska) inačica sustava sličnog priloženom upotrebljava u preventivne svrhe. Ljudsko srce je sofisticiran i nepredvidiv, ponekad kaotičan biološki sat i animator osnovnih aktivnosti organizma, što implicira i afirmaciju njezine uloge u ljudskom životu vođenjem zdravog života, te izgradnju naprednije medicinske instrumentacije.

9. Literatura

- EUROSTAT. (2011). *EUROSTAT*. Preuzeto iz EUROSTAT:
<http://epp.eurostat.ec.europa.eu/portal/page/portal/eurostat/home/>
- Green, J. M., & Chiaramida, A. J. (2010). *12-Lead EKG Confidence A Step-by-Step Guide, Second Edition*. Springer Publishing Company, LLC.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*. Prentice-Hall, Inc.
- Jandrić, B. (n.d.). *Anatomija srca*. Preuzeto iz
<http://www.znanje.org/i/i26/06iv07/06iv0710/Anatomija%20srca.htm>
- Koronarne arterije*. (10. 2. 2011). Preuzeto iz Perpetuum Lab: http://perpetuum-lab.com.hr/forum/page/wiki/plab_wiki/_/anatomija-enciklopedija/koronarne-arterije-r60
- Lončarić, S. (2010). *Neuronske mreže, uvodno predavanje*. Zagreb, Hrvatska.
- Lourakis, M. I. (2005). *A Brief Description of the Levenberg-Marquardt Algorithm Implemented*.
- Moody, G. B. (24. 6. 2010). *MIT-BIH Arrhythmia Database*. Preuzeto iz PhysioBank:
<http://www.physionet.org/physiobank/database/html/mitdbdir/intro.htm>
- Polikar, R. (2000). *Wavelet Tutorial*. Preuzeto iz
<http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html>
- Sahab, A. R., & Gilmalek, Y. M. (2011). An Automatic Diagnostic Machine for ECG Arrhythmias classification Based on Wavelet Transformation and Neural Networks.
- Šantić, A. (1995). *Biomedicinska elektronika*. Zagreb: Školska knjiga.
- tansig (Neural Network Toolbox)*. (n.d.). Preuzeto iz
<http://dali.feld.cvut.cz/ucebna/matlab/toolbox/nnet/tansig.html>
- The MathWorks, Inc. (2007). *Levenberg-Marquardt (trainlm) :: Backpropagation (Neural Network Toolbox)*. Preuzeto iz
http://www.kxcad.net/cae_MATLAB/toolbox/nnet/backpr17.html
- Walnut, D. F. (2002). *An Introduction to Wavelet Analysis*.
- Wikipedia. (30. 5. 2011). *Daubechies wavelet*. Preuzeto iz Wikipedia:
http://en.wikipedia.org/wiki/Daubechies_wavelet
- Wikipedia. (23. 4. 2011). *Left bundle branch block*. Preuzeto iz Wikipedia:
http://en.wikipedia.org/wiki/Left_bundle_branch_block

Wikipedia. (25. 5. 2011). *Right bundle branch block*. Preuzeto iz Wikipedia:
http://en.wikipedia.org/wiki/Right_bundle_branch_block

Ostali izvori:

Slika 2 preuzeta je sa stranice *Wikipedija - Srce*: <http://hr.wikipedia.org/wiki/Srce>

Slika 11 preuzeta je sa stranice *flashback humour*: <http://rush3k.blog-city.com/arrgrhhh.htm>

Slika 17 preuzeta je sa stranice *Wikipedija - Živčano tkivo*:
http://hr.wikipedia.org/wiki/%C5%BDiv%C4%8Dano_tkivo

Sažetak

Klasifikacija srčanih ritmova neuronskom mrežom

U ovom radu prezentiran je sustav za automatsku klasifikaciju EKG signala u klase: normalan srčani ritam, blokada lijevog provodnog bloka, te blokada desnog provodnog bloka. Uz ekstrakciju značajki pomoću wavelet dekompozicije Daubechies 6 waveletom izvršen je trening neuronske mreže, te su izvedeni testovi kako bi se utvrdila točnost klasifikacije. Statistička analiza pokazala je zadovoljavajuće rezultate iz oba primijenjena skupa uzoraka. Iako baza pacijenata kojom je raspolagao izgrađeni klasifikator nije bila opsežna, omogućila je uvid u mogućnosti na području medicinske dijagnostike.

Ključne riječi: automatska klasifikacija, diskretna wavelet transformacija, Daubechies 6, db6, neuronska mreža, EKG, normalan srčani ritam, blokada lijevog provodnog bloka, blokada desnog provodnog bloka, medicinska dijagnostika

Abstract

Automatic classification of heartbeats using neural network classifier

In this paper, a system for automatic classification of ECG signals is presented. The following classes of heartbeats were covered: normal heart rhythm, left bundle branch block (LBBB) and right bundle branch block (RBBB). Using discrete wavelet transfer with Daubechies 6 wavelet, features were extracted and given to a neural network. Several testings were executed for statistical purposes, which proved satisfactory. Although the used database wasn't extensive, the whole process enabled an insight into the possibilities of information processing in medical diagnostics.

Keywords: automatic classification, discrete wavelet transform, Daubechies 6, db6, neural network, ECG, normal heartbeat, left bundle branch block, LBBB, right bundle branch block, RBBB, medical diagnostics